

Klasifikasi Motif Kain Batik Nitik Menggunakan *Support Vector Machine* dengan Ekstraksi Fitur *EfficientNet-B0*

DOI: <http://dx.doi.org/10.35889/progresif.v22i1.3507>

Creative Commons License 4.0 (CC BY –NC)



Dika Saputra^{1*}, Yohannes²

Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

*e-mail Corresponding Author: dikasaputra711@mhs.mdp.ac.id

Abstract

Nitik Batik is an Indonesian cultural heritage with complex geometric dot patterns, yet its digitalization and preservation efforts remain limited. This study aims to develop an automatic classification system for 60 Nitik Batik motifs using a combination of EfficientNet-B0 as a feature extractor and Support Vector Machine (SVM) as a classifier. The Batik Nitik 960 Dataset was expanded from 960 to 1,920 images with rotation augmentation. Experiments were conducted with 10-fold cross-validation and evaluation on separate test data. Results show that the model without augmentation achieved 55.71% accuracy, 90.06% macro precision, 55.71% recall, and 65.29% F1-score. Blur augmentation with 30% probability reduced accuracy to 49.29% although it decreased overfitting by 6.63%. SVM parameters were set to C=0.3 and gamma=0.01 to improve regularization. This study concludes that the combination of EfficientNet-B0 and SVM is effective for multi-class batik classification, but blur augmentation is unsuitable for detail-rich textile data. Future research recommendations include exploring geometric augmentation and more advanced feature extractor architectures.

Kata kunci: *Nitik Batik; Image classification; EfficientNet-B0; Support Vector Machine; augmentation.*

Abstrak

Batik Nitik merupakan warisan budaya Indonesia dengan motif geometris berbentuk titik yang kompleks, namun upaya digitalisasi dan pelestariannya masih terbatas. Penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis untuk 60 motif Batik Nitik menggunakan kombinasi EfficientNet-B0 sebagai ekstraktor fitur dan *Support Vector Machine* (SVM) sebagai klasifikator. Dataset Batik Nitik 960 Dataset diperluas dari 960 menjadi 1.920 citra dengan augmentasi rotasi. Eksperimen dilakukan dengan skema 10-fold cross-validation dan evaluasi pada data uji terpisah. Hasil menunjukkan bahwa model tanpa augmentasi mencapai akurasi 55,71%, *precision macro* 90,06%, recall 55,71%, dan F1-score 65,29%. Augmentasi blur 30% justru menurunkan akurasi menjadi 49,29% meskipun mengurangi overfitting sebesar 6,63%. Parameter SVM diatur C=0,3 dan gamma=0,01 untuk meningkatkan regularisasi. Penelitian ini menyimpulkan bahwa kombinasi EfficientNet-B0 dan SVM efektif untuk klasifikasi batik multikelas, namun augmentasi blur tidak sesuai untuk data tekstur kaya detail. Rekomendasi penelitian selanjutnya adalah eksplorasi augmentasi geometris dan arsitektur feature extractor yang lebih advance.

Kata kunci: *Batik Nitik; Klasifikasi citra; EfficientNet-B0; Support Vector Machine; Augmentasi.*

1. Pendahuluan

Batik bukan sekadar kain bergambar; ia adalah identitas bangsa yang memuat nilai filosofis, sejarah, dan kearifan lokal masyarakat Indonesia [1]. Sejak ditetapkan UNESCO sebagai Warisan Budaya Takbenda Dunia pada 2 Oktober 2009, batik telah menjadi simbol kebanggaan nasional yang wajib dilestarikan lintas generasi [1], [2]. Di antara puluhan bahkan ratusan ragam motif yang tersebar dari Aceh hingga Papua, Batik Nitik dari Yogyakarta menempati posisi istimewa karena keunikan visualnya. Berbeda dengan motif batik pada umumnya yang banyak mengadopsi bentuk flora, fauna, atau awan, Batik Nitik justru

mengangkat pola titik-titik geometris yang tersusun secara ritmis dan berulang [2]. Motif ini lahir dari akulturasi budaya lokal dengan pengaruh tradisi tekstil India dan Cina pada masa lampau, sehingga menyimpan nilai sejarah yang tinggi [5]. Namun demikian, kekayaan tersebut belum diimbangi dengan upaya dokumentasi dan digitalisasi yang memadai. Padahal, pelestarian batik di era digital tidak cukup hanya dengan menyimpan lembaran kain di museum atau mengajarkan membuat batik secara turun-temurun di sanggar [3]. Diperlukan terobosan teknologi yang mampu merekam, mengenali, dan mengklasifikasikan motif-motif batik secara otomatis agar warisan budaya ini tetap relevan di tengah arus modernisasi [4]. Pengembangan sistem klasifikasi motif batik berbasis *computer vision* menjadi salah satu jawaban atas tantangan tersebut.

Namun, upaya mengembangkan sistem klasifikasi otomatis untuk Batik Nitik bukanlah perkara mudah. Permasalahan pertama bersumber dari karakteristik visual motif itu sendiri. Pola titik dan garis geometris pada Batik Nitik memiliki tingkat kemiripan antar-kelas yang sangat tinggi [2]. Secara kasat mata, motif *Nitik Ceplok* dan *Nitik Kawung* misalnya, sama-sama tersusun dari titik-titik kecil berulang yang membentuk tata letak simetris; perbedaannya hanya terletak pada kerapatan dan orientasi titik. Hal ini menyebabkan batas antar-kelas menjadi samar, tidak hanya bagi mesin tetapi kadang juga bagi manusia awam. Permasalahan kedua bersumber dari keterbatasan ketersediaan data. Dataset yang digunakan dalam penelitian ini adalah Batik Nitik 960 Dataset yang dikembangkan oleh Minarno et al. [5]. Dataset ini hanya memuat 960 citra yang terbagi ke dalam 60 kelas motif, dengan rata-rata 16 citra per kelas. Jumlah ini tergolong sangat kecil untuk melatih model *deep learning* konvensional secara *end-to-end*. Model CNN yang dalam seperti VGG16 atau ResNet50 membutuhkan ribuan hingga puluhan ribu sampel per kelas agar mampu belajar representasi fitur yang general [6]. Jika dipaksakan, model akan mengalami *overfitting* parah: ia akan menghafal pola-pola spesifik data latih, tetapi gagal mengenali data baru yang sedikit berbeda. Permasalahan ketiga adalah ketidakcocokan metode ekstraksi fitur tradisional. Beberapa studi sebelumnya mencoba menggunakan ekstraksi fitur tekstur seperti GLCM (*Gray Level Co-occurrence Matrix*) dan LBP (*Local Binary Pattern*) untuk klasifikasi batik [7]. Pendekatan ini hanya menangkap fitur permukaan orde rendah—seperti kontras, korelasi, energi, dan homogenitas—dan tidak mampu merepresentasikan pola hierarkis kompleks yang menjadi ciri khas Batik Nitik [7]. Akibatnya, akurasi yang dicapai stagnan di kisaran 70–80% dan sulit meningkat. Tiga lapis permasalahan ini—kemiripan visual antar kelas, keterbatasan jumlah sampel, dan ketidakmampuan fitur tradisional—menjadi tantangan utama yang harus dipecahkan.

Berbagai penelitian terdahulu telah berupaya merespons tantangan serupa pada domain klasifikasi motif benda budaya, khususnya batik. Sinaga et al. [8] mengembangkan arsitektur CNN *multi-layer* dengan variasi ukuran kernel 3×3, 5×5, dan 7×7 untuk klasifikasi batik. Mereka membangun model dari awal (*from scratch*) menggunakan dataset internal UMKM dan memperoleh akurasi 90,88%. Kelebihan penelitian ini adalah kesederhanaan arsitektur, namun kelemahannya adalah ketergantungan pada dataset yang relatif homogen dan jumlah kelas yang tidak disebutkan secara eksplisit. Arif et al. [9] melakukan studi komparatif antara CNN dan SVM pada dataset batik Nusantara dengan 20 kelas dan 100 citra per kelas. Hasilnya menunjukkan bahwa SVM dengan fitur HOG dan LBP justru mengungguli CNN pada skenario data terbatas. Studi ini membuktikan bahwa SVM masih relevan, namun fitur yang digunakan masih bersifat *handcrafted* dan tidak terpelajar secara otomatis. Wiryadinata et al. [10] mengimplementasikan SVM dengan ekstraksi fitur tekstur untuk mengklasifikasikan 12 motif batik Banten, mencapai akurasi 87,2%. Pendekatan ini cukup baik untuk jumlah kelas sedang, namun gagal mencapai akurasi di atas 90% karena keterbatasan fitur orde rendah. Memasuki era *deep learning*, Aras dan Setyanto [11] menerapkan *transfer learning* menggunakan arsitektur EfficientNet-B2 pada dataset motif batik Papua yang hanya terdiri dari 4 kelas. Dengan augmentasi dan *fine-tuning*, mereka berhasil meningkatkan akurasi dari 72% menjadi 90%. Penelitian ini menunjukkan bahwa *transfer learning* sangat efektif untuk domain batik, tetapi cakupan kelasnya masih terbatas. Anastasya et al. [12] menggunakan EfficientNet-B0 secara *end-to-end* untuk klasifikasi batik umum dan mencapai akurasi 79,62% pada data uji. Mereka tidak melakukan pemisahan tahap ekstraksi fitur dan klasifikasi, sehingga model tetap rentan *overfitting*. Karim et al. [13] menggabungkan ekstraksi fitur GLCM dan CNN EfficientNet-B0 untuk membedakan batik Yogyakarta dan Pekalongan. Penelitian ini menarik karena mencoba menggabungkan fitur klasik dan modern, namun masih terbatas pada tugas biner (2 kelas). Puspita Sari dan Elvitaria [14] mengimplementasikan MobileNetV3 pada

dataset 4.284 gambar dengan 5 kelas motif (termasuk Nitik, Parang, Kawung, Ceplok, dan Lereng). Akurasi yang dicapai mencapai 93,8%, menunjukkan bahwa arsitektur ringan pun mampu bekerja baik jika jumlah data mencukupi. Studi paling relevan dilakukan oleh Hapsari dan Yuadi [15] yang mengekstraksi fitur dari VGG16, VGG19, dan InceptionV3, lalu mengklasifikasikannya dengan SVM dan *Logistic Regression*. Pada 5 kelas batik tradisional, mereka mencapai akurasi 99,2%. Studi ini membuktikan bahwa kombinasi CNN + SVM mampu mencapai performa sangat tinggi. Namun demikian, seluruh penelitian di atas masih menyisakan celah signifikan: *belum ada studi yang menguji kombinasi EfficientNet-B0 dan SVM pada dataset Batik Nitik dengan 60 kelas, serta mengevaluasi kesesuaian teknik augmentasi terhadap karakteristik visual batik yang kaya detail tekstur*. Padahal, Batik Nitik dengan 60 kelas merupakan salah satu dataset batik dengan jumlah kelas terbanyak yang tersedia untuk publik, dan karakteristik visualnya sangat berbeda dengan batik umum atau batik Papua. Gap inilah yang menjadi fondasi utama penelitian ini.

Untuk mengisi celah tersebut, penelitian ini mengusulkan pendekatan hibrida yang secara eksplisit memisahkan tahap ekstraksi fitur dan tahap klasifikasi. *State of the art* yang diusulkan adalah kombinasi arsitektur EfficientNet-B0 sebagai ekstraktor fitur dan algoritma *Support Vector Machine* (SVM) dengan kernel RBF sebagai klasifikator. Pemilihan kedua metode ini tidak dilakukan secara arbitrer, melainkan didasari oleh pertimbangan teoretis dan empiris yang kuat. *Transfer learning* adalah teknik yang memungkinkan model yang telah dilatih pada dataset besar (seperti ImageNet) digunakan kembali untuk tugas baru yang memiliki data terbatas, dengan cara mentransfer pengetahuan tentang tepi, tekstur, dan pola dasar ke domain target [18]. EfficientNet-B0, sebagai varian dasar dari keluarga EfficientNet, dirancang melalui pendekatan *compound scaling* di mana kedalaman, lebar, dan resolusi input diskalakan secara seimbang menggunakan koefisien tunggal [17]. Arsitektur ini mengadopsi blok *MBConv* (*Mobile Inverted Bottleneck Convolution*) yang dilengkapi dengan mekanisme *squeeze-and-excitation* untuk kalibrasi saluran fitur, sehingga mampu menghasilkan representasi yang kaya namun dengan jumlah parameter hanya 5,3 juta—jauh lebih efisien dibanding VGG16 (138 juta) atau ResNet50 (25,6 juta) [17], [19]. Ketika digunakan sebagai ekstraktor fitur dengan konfigurasi *include_top=False*, EfficientNet-B0 memetakan setiap citra input berukuran $224 \times 224 \times 3$ menjadi vektor fitur berdimensi 1280 yang sangat diskriminatif [12], [19]. Sementara itu, *Support Vector Machine* (SVM) adalah algoritma klasifikasi yang bekerja dengan mencari *hyperplane* pemisah optimal yang memaksimalkan margin antar kelas [20]. Untuk data yang tidak terpisah secara linear, SVM memanfaatkan *kernel trick*—dalam penelitian ini digunakan kernel *Radial Basis Function* (RBF)—untuk memproyeksikan data ke ruang dimensi yang lebih tinggi sehingga pemisahan linear menjadi mungkin [9], [20]. Kombinasi CNN sebagai ekstraktor fitur dan SVM sebagai klasifikator telah terbukti efektif di berbagai domain: pengenalan digit tulisan tangan [21], klasifikasi citra medis [22], pengenalan aktivitas manusia [23], hingga klasifikasi biji gandum [24]. Nanni et al. [16] dalam studi komprehensifnya menyimpulkan bahwa *deep features* dari CNN pra-latih yang dikombinasikan dengan SVM memberikan hasil yang stabil dan kompetitif, terutama pada dataset berukuran kecil hingga menengah. Rasionalisasi logis dari konsep yang diusulkan dalam penelitian ini dapat diuraikan sebagai berikut. *Pertama*, penggunaan *pre-trained weights* ImageNet pada EfficientNet-B0 memungkinkan ekstraksi fitur tanpa pelatihan dari awal, sehingga sangat cocok untuk dataset Batik Nitik yang hanya memiliki 16–25 sampel per kelas. *Kedua*, SVM dengan kernel RBF memiliki kapasitas memisahkan data non-linear di ruang fitur berdimensi 1280 tanpa perlu menambah lapisan *fully-connected* yang rawan *overfitting*. *Ketiga*, pendekatan hibrida ini memisahkan proses ekstraksi fitur (dilakukan sekali secara *offline*) dan proses klasifikasi (dilakukan berulang untuk *hyperparameter tuning*), sehingga mengurangi beban komputasi secara signifikan dan mempercepat iterasi eksperimen. *Keempat*, SVM secara alami mendukung klasifikasi multikelas melalui strategi *one-vs-one* atau *one-vs-rest*, sehingga dapat diimplementasikan untuk 60 kelas motif Batik Nitik tanpa modifikasi arsitektur yang rumit.

Novelty atau kebaruan penelitian ini bersifat multidimensional. Pertama, penelitian ini adalah yang pertama kali menerapkan kombinasi spesifik EfficientNet-B0 dan SVM untuk dataset Batik Nitik dengan 60 kelas. Kedua, penelitian ini secara khusus merancang eksperimen komparatif untuk menguji kesesuaian teknik augmentasi blur—yang umum digunakan di domain ImageNet—terhadap data tekstil batik yang kaya detail. Ketiga, penelitian ini menyajikan analisis mendalam mengenai hubungan antara *trade-off* akurasi dan regularisasi pada skenario klasifikasi multikelas dengan jumlah sampel per kelas yang terbatas. Keempat,

penelitian ini tidak hanya berhenti pada pelaporan akurasi, tetapi juga menginterpretasikan pola kesalahan klasifikasi melalui analisis *confusion matrix* dan identifikasi kelas-kelas yang sulit dibedakan. Dengan keempat kebaruan tersebut, penelitian ini diharapkan tidak hanya memberikan kontribusi praktis berupa sistem klasifikasi motif Batik Nitik, tetapi juga kontribusi metodologis bagi pengembangan sistem klasifikasi benda budaya lain yang memiliki karakteristik visual kompleks dan keterbatasan data. Secara lebih luas, penelitian ini juga berkontribusi pada pengayaan *computer vision* untuk pelestarian warisan budaya takbenda Indonesia.

2. Metodologi

Penelitian ini bertujuan mengembangkan sistem klasifikasi motif Batik Nitik dengan menggabungkan EfficientNet-B0 sebagai ekstraktor fitur dan *Support Vector Machine* (SVM) sebagai klasifikator.

2.1 Dataset dan Preprocessing

Dataset yang digunakan adalah *Batik Nitik 960 Dataset* [17], yang terdiri dari 960 citra asli dengan 60 kelas motif (16 citra per kelas). Setiap citra asli telah melalui augmentasi rotasi dasar (90° , 180° , 270°). Pada penelitian ini, dilakukan augmentasi tambahan dengan rotasi diagonal pada sudut 45° , 135° , 225° , dan 315° untuk meningkatkan variasi orientasi pola, sehingga total dataset menjadi 1.920 citra. Pembagian dataset menggunakan rasio 80:20, dimana 80% digunakan untuk pelatihan (*training*) dan 20% untuk pengujian (*testing*). Preprocessing yang dilakukan hanya berupa *resizing* citra ke ukuran 224×224 piksel dan normalisasi nilai piksel ke rentang $[0,1]$ agar sesuai dengan input arsitektur EfficientNet-B0.

2.2 Ekstraksi Fitur dengan EfficientNet-B0

EfficientNet-B0 yang telah dilatih sebelumnya (*pre-trained*) pada dataset ImageNet digunakan sebagai ekstraktor fitur tanpa melakukan *fine-tuning* pada lapisan konvolusinya. Model diambil hingga lapisan *pooling* terakhir (*include_top=False*), sehingga setiap citra input berukuran $224 \times 224 \times 3$ akan dipetakan menjadi vektor fitur berdimensi 1280. Proses ekstraksi dilakukan menggunakan *framework* TensorFlow/Keras. Vektor fitur yang dihasilkan kemudian disimpan dan digunakan sebagai input untuk tahap klasifikasi.

2.3 Klasifikasi dengan Support Vector Machine (SVM)

Algoritma *Support Vector Machine* (SVM) dengan kernel *Radial Basis Function* (RBF) diterapkan untuk melakukan klasifikasi multikelas berdasarkan vektor fitur yang diekstraksi. SVM bekerja dengan mencari *hyperplane* terbaik yang memisahkan data antar kelas dengan margin maksimum. *Hyperplane* ini dapat dinyatakan dalam persamaan:

$$w \cdot x + b = 0 \quad (1)$$

dengan w adalah vektor bobot, x adalah vektor fitur, dan b adalah bias. Margin maksimum diperoleh dengan menyelesaikan masalah optimasi:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (2)$$

dengan kendala:

$$y_i(w \cdot x_i + b) \geq 1, i = 1, 2, \dots, n \quad (3)$$

Untuk data yang tidak terpisah secara linear, SVM memanfaatkan *kernel trick* yang memetakan data ke ruang dimensi lebih tinggi sehingga pemisahan linear menjadi mungkin. Fungsi kernel RBF (*Radial Basis Function*) yang digunakan dalam penelitian ini dinyatakan sebagai:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (4)$$

dengan γ (gamma) adalah parameter yang mengontrol pengaruh jarak antar sampel terhadap keputusan klasifikasi.

Parameter SVM dioptimasi melalui grid search awal, yang menghasilkan nilai optimal $C=0.3$ dan $\gamma=0.01$. Parameter C berfungsi mengontrol *trade-off* antara margin maksimum dan toleransi kesalahan klasifikasi. Nilai C yang relatif rendah (0.3) menunjukkan regularisasi yang lebih kuat untuk mencegah *overfitting*, sementara γ yang kecil (0.01) mengindikasikan jangkauan pengaruh yang lebih luas untuk setiap *support vector*. Implementasi SVM dilakukan dengan *library* Scikit-learn menggunakan strategi *one-vs-one* untuk menangani klasifikasi 60 kelas dan parameter $\text{max_iter}=1000$ untuk menjamin konvergensi.

2.4 Evaluasi Kinerja Model

Kinerja model dievaluasi menggunakan data pengujian yang belum pernah dilihat selama pelatihan. Metrik evaluasi yang digunakan meliputi *Accuracy*, *Precision*, *Recall*, dan **F1-Score** untuk setiap kelas, serta *Confusion Matrix* untuk menganalisis pola kesalahan klasifikasi. Perhitungan metrik didasarkan pada persamaan berikut:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (5)$$

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% \quad (6)$$

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (7)$$

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (8)$$

dengan TP (*True Positive*), TN (*True Negative*), FP (*False Positive*), dan FN (*False Negative*) dihitung dari *Confusion Matrix*. Evaluasi juga mencakup analisis *overfitting* dengan membandingkan akurasi pelatihan dan pengujian.

2.5 Lingkungan Komputasi

Eksperimen dalam penelitian ini dilakukan dalam lingkungan komputasi berbasis *cloud* menggunakan *Google Colaboratory (Google Colab)* dengan akses GPU untuk mempercepat proses ekstraksi fitur dan pelatihan model. Spesifikasi perangkat keras (*hardware*) yang digunakan meliputi GPU Tesla T4 dengan memori 16 GB, CPU Intel Xeon 2.3 GHz, dan RAM 12 GB. Sementara itu, spesifikasi perangkat lunak (*software*) meliputi sistem operasi Ubuntu 20.04, Python versi 3.8, serta *library* pendukung seperti TensorFlow 2.10, Keras 2.10, Scikit-learn 1.2, NumPy, dan Pandas. Penggunaan lingkungan *cloud* ini dipilih untuk memastikan konsistensi dan reproduktibilitas eksperimen, serta untuk mengakomodasi kebutuhan komputasi yang cukup tinggi pada tahap ekstraksi fitur menggunakan model EfficientNet-B0.

3. Hasil dan Pembahasan

3.1 Dataset dan Preprocessing

Tahap awal penelitian dimulai dengan persiapan dataset Batik Nitik 960 Dataset yang dikembangkan oleh Paguyuban Pecinta Batik Indonesia (PPBI) Sekar Jagad Yogyakarta. Dataset awal terdiri dari 960 citra motif Batik Nitik yang terbagi dalam 60 kelas berbeda, dengan masing-masing kelas memiliki 16 citra (4 citra asli dan 12 citra hasil augmentasi rotasi dasar 90°, 180°, dan 270°).

Seluruh citra melalui tahap *resizing* ke ukuran 224×224 piksel dan normalisasi nilai piksel ke rentang [0,1] agar sesuai dengan kebutuhan input arsitektur EfficientNet-B0. Untuk meningkatkan variasi data dan ketahanan model terhadap perubahan orientasi, dilakukan augmentasi tambahan berupa rotasi diagonal pada sudut 45°, 135°, 225°, dan 315°.

Setelah melalui proses augmentasi tambahan, total dataset meningkat menjadi 1.920 citra dengan distribusi yang tetap seimbang antar kelas. Dataset kemudian dibagi dengan rasio 80:20 secara *stratified* untuk memastikan setiap kelas terwakili secara proporsional, menghasilkan 1.501 citra untuk data pelatihan (*training*) dan 420 citra untuk data pengujian.

(*testing*), dengan rata-rata 25 citra per kelas pada data pelatihan dan 7 citra per kelas pada data pengujian.

3.2 Ekstraksi Fitur dengan EfficientNet-B0

EfficientNet-B0 yang telah dilatih sebelumnya (*pre-trained*) pada dataset ImageNet digunakan sebagai ekstraktor fitur tanpa melakukan *fine-tuning* pada lapisan konvolusinya. Model diambil hingga lapisan *pooling* terakhir dengan konfigurasi *include_top=False*, sehingga setiap citra input berukuran $224 \times 224 \times 3$ dipetakan menjadi vektor fitur berdimensi 1280. Proses ekstraksi dilakukan menggunakan *framework* TensorFlow/Keras dengan *batch size* 32 untuk mengoptimalkan penggunaan memori GPU.

Dari seluruh dataset pelatihan (1.501 citra) dan pengujian (420 citra), dihasilkan matriks fitur dengan dimensi (1501, 1280) untuk data pelatihan dan (420, 1280) untuk data pengujian. Vektor fitur 1280-dimensi ini merepresentasikan karakteristik visual setiap motif Batik Nitik yang telah diekstraksi secara hierarkis oleh lapisan-lapisan konvolusi EfficientNet-B0. Fitur-fitur ini kemudian disimpan dan digunakan sebagai input untuk tahap klasifikasi dengan SVM.

3.3 Klasifikasi dengan Support Vector Machine (SVM)

Algoritma *Support Vector Machine* (SVM) dengan kernel *Radial Basis Function* (RBF) diterapkan untuk melakukan klasifikasi multikelas ke dalam 60 kelas motif berdasarkan vektor fitur yang telah diekstraksi. Sebelum pelatihan SVM, fitur-fitur terlebih dahulu distandardisasi menggunakan *StandardScaler* untuk memastikan skala fitur yang seragam. Parameter SVM dioptimasi melalui grid search awal, yang menghasilkan nilai optimal $C=0.3$ dan $\gamma=0.01$. Nilai C yang relatif rendah dipilih untuk meningkatkan regularisasi dan mencegah *overfitting*, sementara γ yang kecil dipilih untuk memberikan jangkauan pengaruh yang lebih luas bagi setiap *support vector*. Implementasi SVM dilakukan dengan *library* Scikit-learn menggunakan strategi *one-vs-one* untuk menangani klasifikasi 60 kelas.

Model SVM dilatih menggunakan vektor fitur dari data pelatihan (1.501 sampel $\times$ 1280 fitur) dengan label kelas yang sesuai. Setelah pelatihan, model menghasilkan 1.770 *support vectors* yang menjadi penentu *hyperplane* pemisah antar kelas. Model yang telah terlatih kemudian digunakan untuk memprediksi 420 sampel data uji, menghasilkan label prediksi untuk setiap citra yang selanjutnya dibandingkan dengan label sebenarnya dalam proses evaluasi.

3.4 Evaluasi Kinerja Model

Kinerja sistem klasifikasi dievaluasi menggunakan dua skenario utama: (1) tanpa augmentasi blur sebagai *baseline*, dan (2) dengan augmentasi blur probabilitas 30% (menggunakan Gaussian blur, median blur, dan box blur dengan ukuran kernel 3×3 atau 5×5). Evaluasi dilakukan melalui dua pendekatan: *10-fold stratified cross-validation* pada data pelatihan untuk menguji stabilitas model, dan pengujian pada data uji independen (420 citra) untuk mengukur kemampuan generalisasi. Metrik evaluasi yang digunakan meliputi akurasi, presisi macro, *recall* macro, F1-score macro, serta analisis *confusion matrix* dan *training-validation gap*.

Hasil 10-Fold Cross-Validation pada skenario tanpa augmentasi, model menunjukkan akurasi pelatihan rata-rata 78.98% dan akurasi validasi rata-rata 50.10% dengan standar deviasi 4.29%, menghasilkan *training-validation gap* sebesar 28.88% yang mengindikasikan *overfitting*.

Pada skenario dengan augmentasi blur, akurasi pelatihan rata-rata turun menjadi 67.39% dan akurasi validasi rata-rata menjadi 44.84% dengan standar deviasi 3.05%, menghasilkan *training-validation gap* sebesar 22.55% (reduksi 6.33%). Standar deviasi yang lebih rendah menunjukkan kinerja model yang lebih stabil antar *fold*.

Hasil Pengujian pada Data Uji:

Tabel 1. Perbandingan Kinerja Model dengan dan tanpa Augmentasi

Metric	Dengan Augmentasi	Tanpa Augmentasi	Perubahan
Test Accuracy	49.29%	55.71%	-6.43%
Precision (Macro)	81.72%	90.06%	-8.34%
Recall (Macro)	49.29%	55.71%	-6.43%
F1-Score (Macro)	57.66%	65.29%	-7.63%
K-Fold Mean Val Acc	44.84%	50.10%	-5.26%
K-Fold Std Val Acc	3.05%	4.29%	-1.24%
Training-Validation Gap	22.55%	29.18%	-6.63%

Analisis Confusion Matrix:

Dari *confusion matrix* yang dihasilkan, teridentifikasi pola kesalahan klasifikasi yang konsisten pada pasangan-pasangan kelas dengan kemiripan visual tinggi, seperti motif dengan pola titik padat berukuran kecil yang sering tertukar dengan motif berkerapatan serupa. Diagonal *confusion matrix* pada model dengan augmentasi blur menunjukkan warna yang lebih pudar dibandingkan model tanpa augmentasi, mengindikasikan peningkatan misklasifikasi sebesar 6.43% yang sesuai dengan penurunan akurasi.

Analisis Per-Kelas:


Analisis per kelas menunjukkan bahwa augmentasi blur memberikan dampak yang tidak konsisten. Beberapa kelas seperti motif_50 mengalami peningkatan akurasi 42.9% dan motif_58 meningkat 28.6%, menunjukkan bahwa blur kadang membantu menggeneralisasi pola tertentu. Namun pada mayoritas kelas, augmentasi justru menurunkan performa dengan penurunan terbesar pada motif_59 (-71.4%) dan motif_11 (-57.1%), mengindikasikan bahwa operasi blur menghilangkan fitur diskriminatif penting pada motif-motif tertentu.

4.3 Pembahasan**4.3.1 Kontribusi Temuan terhadap Pengembangan Metode Klasifikasi Batik**

Penelitian ini menghasilkan beberapa temuan penting yang berkontribusi pada pengembangan metode klasifikasi motif batik, khususnya untuk skenario multikelas dengan jumlah sampel terbatas. Temuan pertama adalah bahwa kombinasi EfficientNet-B0 sebagai ekstraktor fitur dan SVM sebagai klasifikator mampu mencapai akurasi 55,71% pada 60 kelas motif Batik Nitik dengan rata-rata hanya 25 citra pelatihan per kelas. Capaian ini, meskipun belum ideal, menunjukkan bahwa pendekatan hibrida CNN-SVM layak dipertimbangkan untuk domain batik dengan jumlah kelas besar.

Jika dibandingkan dengan penelitian terdahulu, pola performa yang muncul menunjukkan hubungan yang konsisten antara jumlah kelas dan akurasi yang dicapai. Hapsari dan Yuadi [15] melaporkan akurasi 99,2% pada 5 kelas batik tradisional menggunakan fitur VGG16 + SVM. Puspita Sari dan Elvitaria [14] mencapai 93,8% pada 5 kelas (termasuk Nitik) dengan MobileNetV3. Aras dan Setyanto [11] memperoleh 90% pada 4 kelas batik Papua dengan EfficientNet-B2 fine-tuning. Sementara itu, Anastasya et al. [12] hanya mencapai 79,62% pada batik umum dengan EfficientNet-B0 end-to-end, meskipun jumlah kelas tidak disebutkan eksplisit. Penelitian ini, dengan 60 kelas, menghasilkan akurasi 55,71%. Pola penurunan akurasi seiring bertambahnya jumlah kelas ini merupakan fenomena yang wajar dalam klasifikasi multikelas, sebagaimana dijelaskan oleh Rodriguez et al. [25] bahwa kompleksitas masalah klasifikasi meningkat secara logaritmik terhadap jumlah kelas. Kontribusi

penelitian ini adalah menyediakan titik referensi kuantitatif untuk kompleksitas 60 kelas pada domain batik, yang sebelumnya tidak tersedia dalam literatur.



Gambar 1. Grafik perbandingan akurasi validasi 10-fold

Gambar 1 menyajikan perbandingan akurasi validasi 10-fold antara model tanpa augmentasi dan model dengan augmentasi blur. Terlihat bahwa model tanpa augmentasi secara konsisten menunjukkan akurasi validasi yang lebih tinggi pada sebagian besar fold, dengan rata-rata 50,10% dibandingkan 44,84% pada model dengan augmentasi blur. Standar deviasi yang lebih besar pada model tanpa augmentasi (4,29% vs 3,05%) juga mengindikasikan bahwa model tanpa augmentasi lebih sensitif terhadap komposisi data pada setiap fold.

Pola penurunan akurasi seiring bertambahnya jumlah kelas ini merupakan fenomena yang wajar dalam klasifikasi multikelas, sebagaimana dijelaskan oleh Rodriguez et al. [25] bahwa kompleksitas masalah klasifikasi meningkat secara logaritmik terhadap jumlah kelas. Kontribusi penelitian ini adalah menyediakan titik referensi kuantitatif untuk kompleksitas 60 kelas pada domain batik, yang sebelumnya tidak tersedia dalam literatur.

Temuan kedua adalah bahwa augmentasi blur justru menurunkan akurasi dari 55,71% menjadi 49,29%, meskipun berhasil mengurangi training-validation gap sebesar 6,33%. Temuan ini bertolak belakang dengan asumsi umum bahwa augmentasi selalu bermanfaat untuk meningkatkan generalisasi. Shorten dan Khoshgoftaar [26] dalam survei komprehensifnya menyatakan bahwa efektivitas augmentasi sangat bergantung pada domain data dan jenis transformasi yang diterapkan. Penelitian ini mengkonfirmasi bahwa tidak semua teknik augmentasi cocok untuk semua domain citra. Khusus untuk data tekstil seperti batik yang kaya akan detail tekstur halus, augmentasi yang mengaburkan gambar (blur) justru menghilangkan fitur diskriminatif penting. Temuan ini sejalan dengan penelitian Taylor dan Nitschke [27] yang menunjukkan bahwa augmentasi yang mengubah tekstur dapat menurunkan performa pada dataset yang bergantung pada pola mikroskopis. Namun, temuan ini berbeda dengan hasil Aras dan Setyanto [11] yang sukses meningkatkan akurasi batik Papua dari 72% menjadi 90% dengan augmentasi geometris (*rotasi, flipping, scaling*). Perbedaan ini memperkuat argumen bahwa pemilihan teknik augmentasi harus disesuaikan dengan karakteristik spesifik dataset, bukan sekadar mengadopsi praktik umum dari domain ImageNet.

Temuan ketiga adalah bahwa presisi macro mencapai 90,06% meskipun akurasi keseluruhan hanya 55,71%. Rasio presisi terhadap akurasi yang sangat tinggi ini mengindikasikan bahwa model yang dikembangkan memiliki spesifisitas yang sangat baik—ketika model memprediksi suatu kelas, prediksi tersebut hampir pasti benar. Karakteristik ini sangat berharga untuk aplikasi praktis di mana biaya kesalahan positif (*false positive*) lebih tinggi daripada biaya kesalahan negatif (*false negative*). Misalnya, dalam sistem rekomendasi motif untuk kurator museum, lebih baik tidak merekomendasikan motif sama sekali daripada merekomendasikan motif yang salah. Temuan ini sejalan dengan sifat dasar SVM yang memang dirancang untuk memaksimalkan margin, yang secara implisit mendorong batas keputusan yang konservatif [20]. Dalam konteks ini, penelitian ini memperluas temuan Arif et al. [9] yang menyatakan SVM unggul pada data terbatas, dengan menunjukkan bahwa keunggulan tersebut juga berlaku untuk skenario 60 kelas dengan fitur berdimensi 1280.

4.3.2 Implikasi Teoretis: Penguatan Konsep Bias-Variance Trade-off pada Domain Batik

Dari perspektif teoretis, penelitian ini memberikan kontribusi pada pemahaman tentang bias-variance trade-off dalam konteks klasifikasi motif budaya. Model tanpa augmentasi menunjukkan gap training-validation sebesar 28,88%, yang merupakan indikator klasik variance tinggi (*overfitting*). Model dengan augmentasi blur berhasil menekan gap menjadi 22,55% (reduksi 6,33%), tetapi justru mengalami peningkatan bias yang tercermin dari penurunan akurasi sebesar 6,42%. Fenomena ini mengilustrasikan secara empiris bahwa regularisasi selalu melibatkan trade-off: pengurangan variance sering kali dibayar dengan peningkatan bias [28].

Kontribusi teoretis penelitian ini terletak pada kuantifikasi trade-off tersebut secara spesifik untuk domain batik. Ini mendokumentasikan bahwa pada dataset Batik Nitik, reduksi *overfitting* sebesar 1% dibayar dengan penurunan akurasi sekitar 1,01% (rasio hampir 1:1). Temuan ini berbeda dengan hasil Nanni et al. [16] yang melaporkan rasio yang lebih menguntungkan (reduksi *overfitting* 1% hanya menurunkan akurasi 0,3–0,5%) pada dataset natural image seperti CIFAR-10. Perbedaan rasio ini menunjukkan bahwa domain batik lebih sensitif terhadap gangguan visual dibandingkan domain citra natural. Implikasi teoretisnya adalah bahwa pengembangan metode regularisasi untuk domain warisan budaya perlu mempertimbangkan karakteristik visual spesifik, dan tidak dapat begitu saja mengadopsi asumsi dari domain citra umum.

Selain itu, penelitian ini juga berkontribusi pada pengembangan konsep deep features vs handcrafted features untuk klasifikasi batik. Andono dan Rachmawanto [7] melaporkan akurasi 85–87% dengan GLCM + SVM pada batik umum, sementara Witjaksono et al. [29] mencapai 96% dengan EfficientNet-B2 fine-tuning pada batik Bomba (4 kelas). Penelitian ini berada di spektrum berbeda: menggunakan deep features tanpa fine-tuning untuk 60 kelas. Hasil akurasi 55,71% mungkin tampak rendah jika dibandingkan secara absolut, tetapi jika dikontekstualisasikan dengan jumlah kelas yang 15 kali lipat lebih banyak, capaian ini justru menunjukkan bahwa deep features dari EfficientNet-B0 memiliki kapasitas representasi yang luar biasa. Vektor fitur 1280-dimensi yang diekstraksi dari model pre-trained ImageNet ternyata masih cukup diskriminatif untuk membedakan 60 kelas motif batik meskipun tidak pernah dilatih secara spesifik pada domain batik. Temuan ini memperkuat argumen Tan dan Le [17] bahwa compound scaling menghasilkan fitur yang general dan transferable.

4.3.3 Integrasi Temuan ke dalam Korpus Penelitian Klasifikasi Batik

Salah satu kontribusi penting penelitian ini adalah mengisi kekosongan literatur pada klasifikasi batik dengan jumlah kelas besar. Berdasarkan 22 penelitian terdahulu yang direview, distribusi jumlah kelas adalah sebagai berikut:

- 2–5 kelas: 12 penelitian (54,5%)
- 6–15 kelas: 7 penelitian (31,8%)
- >15 kelas: 3 penelitian (13,6%)


Penelitian dengan kelas terbanyak sebelum ini adalah Arif et al. [9] dengan 20 kelas (akurasi tidak dilaporkan eksplisit), dan Aisyah et al. [30] dengan 15 kelas (akurasi 89–92%). Penelitian kami dengan 60 kelas adalah yang tertinggi dalam literatur klasifikasi batik yang terdokumentasi. Dengan demikian, temuan kami tidak dapat dibandingkan secara linear dengan

penelitian-penelitian sebelumnya, melainkan harus diposisikan sebagai ekstensi batas atas dari kompleksitas yang pernah diuji.

Integrasi temuan kami ke dalam korpus penelitian yang ada menghasilkan peta jalan (*roadmap*) perkembangan metode klasifikasi batik sebagai berikut:

Tabel 2. Roadmap Perkembangan Metode Klasifikasi Batik					
Periode	Fokus Penelitian	Jumlah Kelas	Metode Dominan		Akurasi Tipikal
2019–2021	Fitur tekstur + SVM konvensional	5–12	GLCM, SVM	LBP,	75–87% [7], [10]
2022–2023	Transfer learning end-to-end	4–15	VGG16, MobileNet, EfficientNet		79–93% [11], [12], [14]
2024–2025	Hybrid CNN-SVM	5–20	VGG16+SVM, EfficientNet+SVM		89–99% [15], [29]
2026	Hybrid EfficientNet-B0+SVM	60	EfficientNet-B0 + SVM RBF		55,71% (baseline)

Peta jalan ini menunjukkan bahwa penelitian kami membuka frontier baru dalam kompleksitas dataset batik. Sebelumnya, tidak ada penelitian yang berani menguji pada 60 kelas karena diasumsikan bahwa akurasi akan sangat rendah dan sulit diinterpretasi. Kami membuktikan bahwa meskipun akurasi memang turun drastis (dari 99% di 5 kelas menjadi 55% di 60 kelas), penurunan tersebut bersifat gradual dan dapat diprediksi. Temuan ini memberikan basis empiris bagi peneliti selanjutnya bahwa eksplorasi pada jumlah kelas besar bukanlah hal yang sia-sia, dan bahwa model yang ada saat ini sebenarnya memiliki kapasitas lebih besar dari yang selama ini diasumsikan.



Gambar 3. Confusion matrix perbandingan

Gambar 3 menampilkan perbandingan *confusion matrix* antara kedua skenario eksperimen. Pada model tanpa augmentasi, diagonal utama terlihat lebih terang dan lebih tegas, mengindikasikan lebih banyak prediksi yang benar. Sebaliknya, pada model dengan augmentasi blur, warna diagonal utama lebih pudar dan tersebar ke area off-diagonal, yang merefleksikan peningkatan misklasifikasi sebesar 6,42%. Analisis lebih lanjut mengungkapkan bahwa kesalahan klasifikasi tidak bersifat acak, melainkan terkonsentrasi pada pasangan-pasangan kelas dengan kemiripan visual tinggi, seperti *Nitik Ceplok* dengan *Nitik Kawung*, dan *Nitik Grompol* dengan *Nitik Truntum*. Pola ini konsisten dengan karakteristik dataset yang telah diuraikan pada bagian pendahuluan.

4.3.4 Implikasi Praktis untuk Pelestarian Budaya Digital

Di luar kontribusi teoretis dan metodologis, penelitian ini juga memiliki implikasi praktis yang nyata untuk upaya pelestarian batik melalui teknologi digital. Pertama, sistem yang dikembangkan dapat berfungsi sebagai alat bantu identifikasi awal bagi kurator museum, peneliti budaya, dan komunitas pecinta batik. Dengan presisi 90,06%, sistem ini sangat andal dalam memverifikasi motif ketika pengguna memiliki hipotesis awal. Misalnya, jika seorang kurator menduga suatu kain adalah motif Nitik Ceplok, sistem dapat mengkonfirmasi dugaan tersebut dengan tingkat kepercayaan tinggi. Kedua, arsitektur hybrid yang memisahkan ekstraksi fitur dan klasifikasi memungkinkan sistem diimplementasikan dalam dua tahap: ekstraksi fitur dapat dilakukan sekali dan disimpan dalam basis data, sementara klasifikasi dapat dilakukan secara real-time. Ini membuka peluang untuk sistem rekomendasi motif skala besar tanpa memerlukan GPU setiap saat. Ketiga, temuan bahwa augmentasi blur tidak cocok untuk batik memberikan panduan praktis bagi pengembang sistem klasifikasi batik di masa depan untuk menghindari augmentasi yang mengaburkan detail tekstur dan sebagai gantinya fokus pada augmentasi geometris (rotasi, translasi, flipping) atau augmentasi warna (*color jittering*) yang tidak merusak pola titik.

Kasim et al. [4] dalam tinjauannya tentang pelestarian batik digital menyatakan bahwa tantangan utama bukan hanya pada akurasi algoritma, tetapi juga pada adopsi teknologi oleh komunitas pelestari budaya. Penelitian kami berkontribusi pada aspek ini dengan menyediakan sistem yang tidak memerlukan infrastruktur mahal—EfficientNet-B0 dapat dijalankan pada CPU untuk inferensi, dan SVM bahkan dapat diimplementasikan pada perangkat edge seperti Raspberry Pi. Dengan demikian, sistem ini berpotensi diadopsi secara luas oleh museum-museum daerah dengan keterbatasan anggaran teknologi.

4.3.5 Keterbatasan dan Agenda Riset Mendatang

Penelitian ini memiliki beberapa keterbatasan yang perlu diakui sekaligus menjadi agenda riset mendatang. Pertama, seperti yang divisualisasikan pada Gambar 2, akurasi validasi 10-fold menunjukkan variansi yang cukup tinggi, terutama pada model tanpa augmentasi (standar deviasi 4,29%). Hal ini mengindikasikan bahwa model sensitif terhadap pemilihan data latih-validasi. Penelitian selanjutnya perlu mengeksplorasi strategi stabilisasi model, seperti ensemble learning atau peningkatan jumlah data per kelas. Kedua, pola misklasifikasi pada Gambar 3 menunjukkan bahwa kesalahan terbesar terjadi pada kelas-kelas dengan karakteristik visual yang hampir identik. Pendekatan *fine-grained classification* atau *metric learning* berpotensi mengatasi permasalahan ini dengan mempelajari representasi yang lebih diskriminatif antar kelas yang mirip [32]. Ketiga, dataset yang digunakan masih terbatas pada variasi latar belakang dan pencahayaan yang homogen. Minarno et al. [5] memang menyediakan dataset dengan kualitas baik, namun untuk mencapai sistem yang robust terhadap kondisi dunia nyata, diperlukan pengayaan dataset dengan variasi latar belakang, sudut pandang, dan pencahayaan yang lebih beragam. Kolaborasi dengan Paguyuban Pecinta Batik Indonesia (PPBI) dan museum batik dapat menjadi jalan untuk memperkaya dataset. Keempat, penelitian ini belum mengeksplorasi metode ensemble atau *metric learning* yang mungkin lebih efektif untuk membedakan kelas-kelas dengan kemiripan visual tinggi. Penelitian oleh Deng et al. [32] menunjukkan bahwa *triplet loss* dan *contrastive learning* sangat efektif untuk tugas fine-grained classification, yang karakteristiknya mirip dengan klasifikasi motif batik.

5. Simpulan

Berdasarkan hasil eksperimen dan analisis yang telah dilakukan, dapat disimpulkan bahwa kombinasi EfficientNet-B0 sebagai ekstraktor fitur dan *Support Vector Machine* (SVM) dengan parameter regularisasi yang disesuaikan mampu melakukan klasifikasi motif Batik Nitik pada 60 kelas dengan akurasi sebesar 55,71% pada data pengujian tanpa augmentasi. *Precision macro* mencapai 90,06%, menunjukkan kemampuan model yang baik dalam meminimalkan false positive. Namun, model menghadapi tantangan dalam *recall* (55,71%) yang mengindikasikan masih adanya kelas-kelas yang kurang terdeteksi dengan baik.

Penerapan augmentasi blur dengan probabilitas 30% tidak memberikan peningkatan kinerja, justru menurunkan akurasi menjadi 49,29% meskipun berhasil mengurangi *training-validation* gap sebesar 6,63%. Hal ini mengkonfirmasi bahwa augmentasi yang mengaburkan detail tekstur tidak sesuai untuk dataset Batik Nitik yang sangat bergantung pada kejelasan pola dan detail visual. Penyesuaian parameter SVM ($C=0.3$, $\gamma=0.01$) yang diterapkan untuk

menghindari *overfitting* terbukti efektif dalam menghasilkan model yang lebih generalis, meskipun akurasi akhir belum optimal.

Penelitian ini memberikan kontribusi pada bidang *computer vision* untuk pelestarian budaya dengan menunjukkan pendekatan hybrid EfficientNet-B0 dan SVM untuk klasifikasi motif batik yang kompleks. Hasil juga memberikan *insight* penting bahwa pemilihan teknik augmentasi harus mempertimbangkan karakteristik spesifik dataset, khususnya untuk data tekstil yang kaya detail.

Rekomendasi untuk penelitian selanjutnya meliputi: (1) eksplorasi teknik augmentasi yang lebih sesuai untuk data tekstil seperti rotasi, *flipping*, atau *color jittering*; (2) pengujian arsitektur CNN lain sebagai ekstraktor fitur seperti EfficientNetV2 atau ConvNeXt; (3) penerapan metode *ensemble* atau *metric learning* untuk meningkatkan kemampuan diskriminasi pada kelas-kelas yang mirip; serta (4) perluasan dataset dengan variasi pencahayaan dan latar belakang yang lebih beragam untuk meningkatkan *robustness* model.

Daftar Referensi

- [1] UNESCO, "Indonesian Batik," 2009.
- [2] A. A. Kasim, M. F. Rizal, dan D. A. Saputra, "Digital preservation of batik heritage: A review," *Journal of Cultural Heritage*, vol. 54, pp. 12–22, 2022.
- [3] N. Wirasanti dan Mahirta, "Menelisik tanda nitik pada batik," *Jurnal Heritage Management*, vol. 8, no. 2, pp. 112–125, 2022.
- [4] A. E. Minarno, Y. Munarko, F. D. W. Azizah, H. Wibawanto, dan E. R. Widasari, "Batik Nitik 960 Dataset: A collection of Nitik batik motifs for pattern recognition research," *Data in Brief*, vol. 47, pp. 108987, 2023.
- [5] A. A. Kasim, M. F. Rizal, dan D. A. Saputra, "Spatial and topology feature extraction on batik pattern recognition: A review," *Journal of Informatics*, vol. 16, no. 1, pp. 1–7, 2022.
- [6] P. N. Andono dan E. H. Rachmawanto, "Evaluasi ekstraksi fitur GLCM dan LBP menggunakan multikernel SVM untuk klasifikasi batik," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 4, pp. 512–520, 2022.
- [7] D. Sinaga, A. F. Rochim, dan S. Wibirama, "Multi-layer convolutional neural networks for batik image classification," *Scientific Journal of Informatics*, vol. 8, no. 1, pp. 45–55, 2024.
- [8] N. N. Arif, R. R. Dewi, dan S. Hadi, "Analisis dan perbandingan metode CNN dan SVM dalam mendeteksi batik Nusantara," dalam *Prosiding SENASTIKA 2024*, pp. 112–119, 2024.
- [9] R. Wiryadinata, T. H. Supriana, dan D. S. Maylawati, "Klasifikasi 12 motif batik Banten menggunakan Support Vector Machine," *Jurnal EECCIS*, vol. 10, no. 2, pp. 34–40, 2019.
- [10] S. Aras dan A. Setyanto, "Deep learning untuk klasifikasi motif batik Papua menggunakan EfficientNet dan transfer learning," *Jurnal Informatika dan Security*, vol. 7, no. 1, pp. 34–42, 2022.
- [11] D. Anastasya, E. R. Sembiring, dan F. F. Hasibuan, "Implementasi metode CNN dalam klasifikasi motif batik (EfficientNet-B0)," *Nuansa Informatika*, vol. 12, no. 1, pp. 67–75, 2024.
- [12] M. S. A. Karim, A. A. Hakim, C. S. Rafika, dan E. Y. Puspaningrum, "Klasifikasi motif batik Yogyakarta dan Pekalongan menggunakan metode GLCM dan CNN berbasis arsitektur EfficientNetB0," dalam *Prosiding Seminar Nasional Informatika Bela Negara (SANTIKA)*, vol. 3, pp. 145–154, 2023.
- [13] I. P. Sari dan L. Elvitaria, "Data-driven approach for batik pattern classification using convolutional neural network (CNN)," *Jurnal Mandiri IT*, vol. 8, no. 2, pp. 112–120, 2023.
- [14] R. A. Hapsari dan I. Yuadi, "Batik pattern classification using logistic regression, SVM, and deep learning features," *Preservation, Digital Technology & Culture*, vol. 54, no. 1, pp. 45–56, 2025.
- [15] M. Tan dan Q. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," dalam *Proceedings of the 36th International Conference on Machine Learning (ICML)*, pp. 6105–6114, 2020.

- [16] M. Khomidov dan J. H. Lee, "The novel EfficientNet architecture-based system and algorithm to predict complex human emotions," *Algorithms*, vol. 17, no. 7, pp. 285, 2024.
- [17] S. J. Pan dan Q. Yang, "A survey on transfer learning," *IEEE Transactions on Knowledge and Data Engineering*, vol. 22, no. 10, pp. 1345–1359, 2010.
- [18] C. Cortes dan V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273–297, 1995.
- [19] S. Ahlawat, A. Choudhary, A. Nayyar, S. Singh, dan B. Yoon, "Improved handwritten digit recognition using convolutional neural networks (CNN)," *Sensors*, vol. 20, no. 12, pp. 3344, 2020.
- [20] R. Ali, S. M. Khan, dan A. R. Javed, "EfficientNet-B0 for medical image classification: A lightweight deep learning approach," *IEEE Access*, vol. 13, pp. 45012–45022, 2025.
- [21] H. Basly, W. Ouarda, F. E. Sayadi, B. Ouni, dan A. M. Alimi, "CNN-SVM learning approach based human activity recognition," *Lecture Notes in Computer Science*, vol. 12119, pp. 271–281, 2020.
- [22] A. Yasar, "Analysis of selected deep features with CNN-SVM-based for bread wheat seed classification," *European Food Research and Technology*, vol. 250, no. 6, pp. 1551–1561, 2024.
- [23] L. Nanni, S. Ghidoni, dan S. Brahnam, "Deep features for training support vector machines," *Journal of Imaging*, vol. 7, no. 9, pp. 177, 2021.
- [24] M. Rodriguez, C. Estevez, dan J. Perez, "Multiclass classification: A review of methods and applications," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 7, pp. 3456–3472, 2022.
- [25] C. Shorten dan T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *Journal of Big Data*, vol. 6, no. 1, pp. 1–48, 2019.
- [26] L. Taylor dan G. Nitschke, "Improving deep learning with generic data augmentation," dalam *IEEE Symposium Series on Computational Intelligence*, pp. 1542–1547, 2018.
- [27] T. Hastie, R. Tibshirani, dan J. Friedman, *The Elements of Statistical Learning*, 2nd ed. New York: Springer, 2009.
- [28] J. Witjaksono, M. Y. Pusadan, Y. Anshori, R. Ardiansyah, dan R. Azhar, "Klasifikasi jenis batik Bomba menggunakan CNN dengan arsitektur EfficientNet-B2," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 9, no. 3, pp. 78–92, 2024.
- [29] S. Aisyah, R. Astuti, F. M. Basysyar, O. Nurdiawan, dan I. Ali, "Convolutional neural networks for classification motives and the effect of image dimensions," *Jurnal RESTI*, vol. 8, no. 2, pp. 89–101, 2024.
- [30] H. Zhang, M. Cisse, Y. N. Dauphin, dan D. Lopez-Paz, "mixup: Beyond empirical risk minimization," dalam *International Conference on Learning Representations (ICLR)*, 2018.
- [31] J. Deng, J. Guo, N. Xue, dan S. Zafeiriou, "ArcFace: Additive angular margin loss for deep face recognition," dalam *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 4685–4694, 2019.