



## Evaluasi Model Klasifikasi Motif Batik Lasem Menggunakan Xgboost, Lightgbm, Resnet50, dan Efficientnet-B0

Rakha Naufal Sujana<sup>1\*</sup>, Puspa Indah<sup>2</sup>, Nafisyia Sefa Nur Vinta<sup>3</sup>, Ruben Setiaji<sup>4</sup>

<sup>1-4</sup>Prodi Informatika, Fakultas Teknologi Informasi, Universitas Tarumanagara, Indonesia

[rakhaufalsujana@gmail.com](mailto:rakhaufalsujana@gmail.com)<sup>1</sup>, [puspaindah0707@gmail.com](mailto:puspaindah0707@gmail.com)<sup>2</sup>, [nafisyian7@gmail.com](mailto:nafisyian7@gmail.com)<sup>3</sup>,

[rubensetiaji04@gmail.com](mailto:rubensetiaji04@gmail.com)<sup>4</sup>

\*Penulis Korespondensi: [rakhaufalsujana@gmail.com](mailto:rakhaufalsujana@gmail.com)

**Abstract.** Batik Lasem is recognized for its rich visual complexity, making the identification of its motifs a challenging task that requires reliable image classification techniques. This study aims to evaluate the performance of four classification models LightGBM, XGBoost, ResNet50, and EfficientNetB0 in distinguishing five Batik Lasem motifs: Gunung Ringgit, Kricak/Watu Pecah, Latohan, Nyuk Pitu, and Seritan. The dataset consists of 5,879 images obtained from Mendeley Data and processed through several stages, including normalization, image resizing, and label structuring. For feature-based models, EfficientNetB0 was used as a feature extractor, whereas ResNet50 and EfficientNetB0 were implemented as end-to-end deep learning architectures. Model performance was assessed using 5-Fold Cross-Validation with accuracy, precision, recall, and F1-score as evaluation metrics. The experimental results indicate that LightGBM achieved the highest performance with an average accuracy of 0.9611, followed by XGBoost with an accuracy of 0.9556. Both boosting models demonstrated strong stability in handling the diverse texture characteristics of batik patterns. ResNet50 achieved an accuracy of 0.9029 and maintained solid capability in learning intricate visual features. In contrast, EfficientNetB0 obtained an accuracy of only 0.2343, suggesting that the model requires further optimization to effectively adapt to the high variability of Batik Lasem motifs. Overall, the findings reveal that boosting-based approaches are more effective for batik image classification, offering a solid foundation for future studies focused on deep learning optimization, enhanced augmentation strategies, or the exploration of more advanced architectures.

**Keywords:** Batik Lasem; Batik Motifs; EfficientNetB0; Image Classification; LightGBM.

**Abstrak.** Batik Lasem merupakan salah satu karya budaya yang memiliki kekayaan visual tinggi, sehingga proses identifikasi motifnya memerlukan dukungan teknologi pengolahan citra yang lebih akurat. Penelitian ini bertujuan mengevaluasi kinerja empat model klasifikasi LightGBM, XGBoost, ResNet50, dan EfficientNetB0 dalam mengenali lima jenis motif Batik Lasem, yaitu Gunung Ringgit, Kricak/Watu Pecah, Latohan, Nyuk Pitu, dan Seritan. Dataset penelitian terdiri dari 5.879 citra dari Mendeley Data yang diolah melalui tahapan prapemrosesan seperti normalisasi, pengubahan ukuran citra, serta penataan struktur label. Model boosting memanfaatkan fitur yang diekstraksi menggunakan EfficientNetB0, sedangkan ResNet50 dan EfficientNetB0 diterapkan sebagai model deep learning secara end-to-end. Evaluasi performa dilakukan menggunakan skema 5-Fold Cross-Validation dengan akurasi, presisi, recall, dan F1-score sebagai metrik utama. Hasil eksperimen menunjukkan bahwa LightGBM menjadi model dengan performa tertinggi dengan rata-rata akurasi 0.9611, diikuti oleh XGBoost yang mencatat akurasi 0.9556. Kedua algoritma ini terbukti mampu mengolah karakteristik tekstur batik dengan stabil. ResNet50 menghasilkan akurasi 0.9029 dan tetap menunjukkan kemampuan kuat dalam menangkap pola visual yang kompleks. Sebaliknya, EfficientNetB0 hanya memperoleh akurasi 0.2343, mengindikasikan bahwa model tersebut memerlukan strategi optimasi tambahan untuk dapat beradaptasi dengan variasi motif Batik Lasem. Temuan ini menunjukkan bahwa metode boosting lebih efektif digunakan pada dataset batik dengan struktur pola beragam, serta menjadi dasar bagi pengembangan penelitian lanjutan melalui optimasi model deep learning, penambahan augmentasi, maupun eksplorasi arsitektur yang lebih mutakhir.

**Kata Kunci:** Batik Lasem; EfficientNetB0; Klasifikasi Citra; LightGBM; Motif Batik.

### 1. LATAR BELAKANG

Batik Lasem merupakan salah satu warisan budaya Indonesia yang memiliki ciri visual khas, terutama dari segi ornamen, komposisi warna, dan nilai historisnya. Batik ini dikenal dengan pengaruh budaya Tionghoa–Jawa yang kuat, serta kerumitan motif seperti Kricak/Watu Pecah, Gunung Ringgit, Seritan, Latohan, dan Nyuk Pitu (Wardana et al., 2021). Dalam

beberapa tahun terakhir, upaya pelestarian dan digitalisasi batik mengalami perkembangan signifikan, termasuk melalui studi mengenai visualisasi motif, dokumentasi digital, dan pengembangan desain berbasis (Sofiani et al., 2025). Penelitian mengenai Batik Lasem juga dilakukan dalam konteks pelestarian ekonomi kreatif dan inovasi desain, seperti visualisasi motif Kricak oleh Maghfiroh & Umami (2022) dan pengembangan desain batik Lasem oleh (Prasetyo & Disarifianti, 2021). Berbagai kajian tersebut menunjukkan pentingnya dokumentasi serta analisis motif Batik Lasem secara lebih terstruktur, terutama dalam memanfaatkan teknologi untuk tujuan preservasi maupun klasifikasi.

Beberapa penelitian sejenis telah menggunakan metode machine learning dan deep learning untuk melakukan pengenalan motif batik. Sutrisno et al. (2021) menerapkan CNN untuk klasifikasi batik pesisir dan berhasil mencapai akurasi di atas 85%, menegaskan kemampuan arsitektur konvolusional dalam menangkap pola visual kompleks (Jaeni et al., 2024). Hafidza (2025) mengevaluasi performa ResNet50 pada motif batik Jawa Tengah dan melaporkan akurasi lebih dari 90%, yang menunjukkan keunggulan arsitektur residual dalam mengekstraksi fitur berlapis (Hafidza, 2025). Penelitian lain oleh Sari et al. (2023) menggunakan EfficientNet-B0 untuk klasifikasi batik umum, namun hasilnya sangat bergantung pada strategi augmentasi dan kualitas dataset sehingga performanya tidak selalu stabil (Haryani, 2023). Selain itu, Handhayani et al. (2017) membandingkan LightGBM dan XGBoost berbasis fitur tekstur, menemukan bahwa model boosting cenderung memberikan akurasi lebih stabil dibanding CNN kecil (Handhayani et al., 2017). Berbagai penelitian terkait batik sebelumnya belum memberikan fokus khusus pada Batik Lasem, meskipun motifnya memiliki kompleksitas visual dan tingkat kemiripan antarkelas yang tinggi sehingga memerlukan pendekatan klasifikasi yang lebih tepat. Selain itu, sebagian besar studi masih terbatas pada penggunaan satu algoritma tanpa melakukan perbandingan kinerja model-model modern seperti XGBoost, LightGBM, ResNet50, dan EfficientNetB0, serta belum menerapkan prosedur evaluasi yang mendalam melalui validasi K-Fold.

Selain itu, perkembangan teknologi kecerdasan buatan dan pembelajaran mesin dalam berbagai bidang menunjukkan bahwa pendekatan berbasis model hybrid dan komparatif mampu meningkatkan akurasi serta ketahanan sistem dalam menghadapi kompleksitas data (Danang & Mustofa, 2026; Siswanto et al., 2026). Hal ini mengindikasikan bahwa penerapan berbagai model klasifikasi modern secara bersamaan juga berpotensi memberikan hasil yang lebih optimal dalam pengenalan motif Batik Lasem.

Untuk menjawab keterbatasan tersebut, penelitian ini melakukan analisis komparatif terhadap empat model klasifikasi modern dengan memanfaatkan teknik ekstraksi fitur dan

validasi K-Fold dalam mengenali motif Batik Lasem. Temuan penelitian ini diharapkan mampu memberikan kontribusi terhadap pengembangan sistem identifikasi batik yang lebih akurat, sekaligus mendukung upaya digitalisasi dan pelestarian budaya berbasis teknologi.

## 2. METODE PENELITIAN

### XGboost

XGBoost merupakan pengembangan lanjutan dari metode Gradient Boosting yang memanfaatkan rangkaian pohon keputusan sebagai *weak learner*. Tidak seperti pendekatan Gradient Boosting konvensional yang membangun model secara berurutan, XGBoost dioptimalkan untuk bekerja secara paralel melalui pemrosesan multithreaded, sehingga pelatihan model menjadi lebih cepat, efisien, dan mampu menangani dataset berukuran besar dengan pemanfaatan CPU yang optimal (Akbar et al., 2020; Alqahtani et al., 2020).

Secara umum, proses pembelajaran pada XGBoost diformulasikan melalui fungsi objektif yang menggabungkan *training loss* dan regularisasi sebagai berikut:

$$\mathcal{L} = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (1)$$

dengan komponen regularisasi yang menekan kompleksitas model dirumuskan menjadi:

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (2)$$

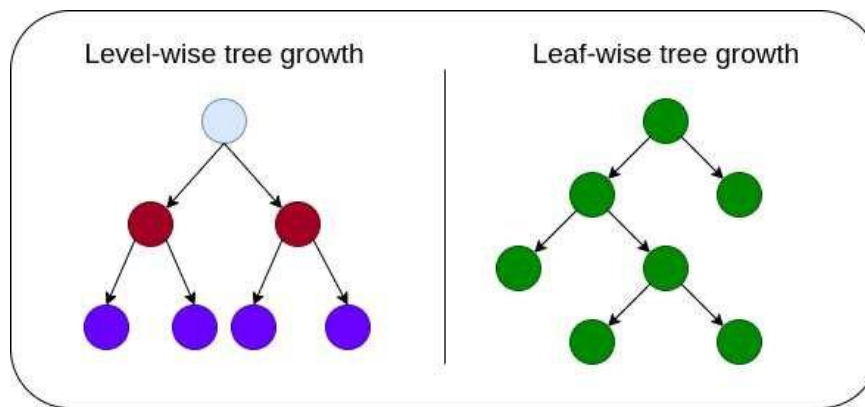
Rumus tersebut membuat XGBoost lebih stabil dengan mengendalikan kompleksitas pohon keputusan yang dibangun, sehingga mengurangi risiko *overfitting*. Selain itu, bobot optimal pada setiap *leaf node* dihitung menggunakan:

$$w_j^* = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (3)$$

XGBoost memperbarui model secara efisien dengan memanfaatkan gradien dan hessian, sehingga proses boosting menjadi lebih optimal. Algoritma ini bersifat *scalable* dan dapat digunakan untuk klasifikasi, regresi, maupun ranking, serta dikenal memiliki akurasi tinggi dan performa yang stabil (Chen & Guestrin, 2016; Yan & Wen, 2021). Popularitasnya dalam berbagai kompetisi machine learning, termasuk Kaggle, menunjukkan keunggulannya dibandingkan metode boosting lain. Fleksibilitas hyperparameter seperti learning rate dan kedalaman pohon turut mendukung kemampuan XGBoost dalam menyesuaikan diri dengan berbagai karakteristik dataset (William, 2025; Aqsha, 2024).

## LightGBM

*Light Gradient Boosting Machine* (LightGBM) adalah algoritma gradient boosting berbasis pohon keputusan yang dikembangkan oleh Microsoft pada tahun 2017. Model ini dirancang untuk bekerja secara efisien pada dataset berukuran besar melalui pendekatan histogram-based tree learning, yaitu teknik pengelompokan nilai fitur ke dalam beberapa bin sehingga proses pemilihan split dapat dilakukan lebih cepat dan hemat memori (Fahmi et al., 2025; Wang et al., 2020). Efisiensi LightGBM diperoleh melalui tiga mekanisme utama: GOSS untuk memprioritaskan sampel bergradien besar, EFB untuk mengurangi dimensi melalui penggabungan fitur eksklusif, serta strategi pertumbuhan pohon *leaf-wise* yang memilih daun dengan peningkatan loss terbesar pada setiap iterasi, sehingga menghasilkan model yang lebih akurat dibandingkan pendekatan *level-wise* tradisional (Rahman et al., 2025). Gambar 1 menggambarkan perbedaan strategi pertumbuhan tersebut.



**Gambar 1.** Pertumbuhan pohon *Level-wise* dan *Leaf-wise*.


LightGBM menyediakan parameter penting seperti *learning rate*, *max depth*, dan *num\_leaves* yang mengatur kompleksitas pohon dan membantu meningkatkan kinerja model pada berbagai jenis dataset. Kombinasi teknik komputasi yang efisien serta fleksibilitas parameter menjadikan LightGBM sebagai salah satu algoritma boosting yang sangat kompetitif untuk tugas klasifikasi dan regresi pada data berskala besar maupun kompleks (Wang & Wang, 2020; Immanuel & Handhayani, 2025).

## ResNet50

ResNet50 merupakan salah satu varian dari arsitektur *Residual Network* (ResNet) dengan kedalaman 50 lapisan yang dirancang untuk mengatasi permasalahan *vanishing gradient* pada jaringan saraf dalam. Model ini menggunakan mekanisme *skip connection*, yaitu jalur pintas yang memungkinkan aliran fitur dan gradien melewati beberapa lapisan sekaligus, sehingga proses pembelajaran menjadi lebih stabil dan mencegah degradasi performa ketika kedalaman

jaringan bertambah. Dengan pendekatan *residual learning* ini, ResNet50 mampu mempelajari representasi fitur yang lebih kompleks secara lebih efisien (Nastitie & Irma, 2025).

Struktur ResNet50 terdiri atas rangkaian *residual block* yang melibatkan operasi konvolusi, *batch normalization*, dan aktivasi ReLU. Desain ini memungkinkan model mempertahankan informasi penting sembari mengekstraksi fitur secara bertahap. Karena kemampuan generalisasi dan kekuatan ekstraksi polanya, ResNet50 banyak digunakan pada berbagai tugas visi komputer seperti klasifikasi, segmentasi, dan deteksi objek (Sihabillah et al., 2025; Wijaya, 2023).



**Gambar 2.** Arsitektur Model ResNet50.

Selain itu, ilustrasi arsitektur ResNet50 pada Gambar 2 menunjukkan tahapan utama mulai dari *convolutional layer*, *identity block*, *convolution block*, hingga *fully connected layer* sebagai bagian akhir proses klasifikasi. Model ini mendapatkan popularitas luas berkat performanya yang sangat baik di berbagai benchmark, termasuk kompetisi ImageNet.

Konsep inti pada arsitektur ResNet, termasuk ResNet50, adalah *residual learning*, yaitu mekanisme yang memungkinkan jaringan mempelajari perbedaan atau *residual* dari suatu transformasi alih-alih langsung mempelajari fungsi kompleks secara keseluruhan. Secara matematis, keluaran dari sebuah residual block dapat dituliskan sebagai:

$$y = F(x, W) + x \quad (4)$$

di mana:

- $x$  merupakan input ke blok residual,
- $F(x, W)$  adalah rangkaian operasi non-linear (Conv–BN–ReLU) yang ditentukan oleh bobot  $W$ ,
- $y$  adalah output setelah melewati jalur utama dan *skip connection*.
- Untuk arsitektur *bottleneck* pada ResNet50, residual function dirumuskan sebagai:

$$F(x) = W_3 \sigma(W_2 \sigma(W_1 x)) \quad (5)$$

dengan  $W_1, W_2, W_3$  masing-masing merepresentasikan bobot pada tiga lapisan konvolusi berurutan ( $1 \times 1$ ,  $3 \times 3$ , dan  $1 \times 1$ ), sedangkan  $\sigma$  adalah fungsi aktivasi ReLU. Dengan demikian, keluaran blok menjadi:

$$y = F(x) + x \quad (6)$$

Formula tersebut menegaskan bahwa skip connection menyediakan jalur pintas bagi gradien, sehingga mengurangi risiko vanishing gradient dan meningkatkan stabilitas pelatihan.

### EfficientB0

EfficientNet merupakan arsitektur *Convolutional Neural Network* (CNN) yang diperkenalkan oleh Tan dan Le (2019) melalui pendekatan *compound scaling*, yaitu strategi penskalaan yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara proporsional. Pendekatan ini memungkinkan peningkatan performa tanpa menambah jumlah parameter dan beban komputasi secara signifikan, sehingga EfficientNet menjadi salah satu model paling efisien dalam tugas *computer vision* (Stanley et al., 2022). Model dasarnya, EfficientNet-B0, memanfaatkan blok MBConv dari MobileNetV2 serta mekanisme Squeeze-and-Excitation (SE) untuk menonjolkan fitur penting. Varian berikutnya, EfficientNet-B1 hingga B7, dibangun dari pengembangan terukur melalui peningkatan kedalaman, lebar, dan resolusi input (Hardi, 2021). Setiap model memiliki resolusi masukan berbeda, mulai dari 224 piksel (B0) hingga 600 piksel (B7), sebagaimana disajikan pada Tabel 1. Konsep *compound scaling* ini divisualisasikan pada Gambar 3 sebagai perbandingan antara metode penskalaan konvensional dan penskalaan terintegrasi pada EfficientNet. Rekomendasi resolusi tiap model ditunjukkan pada Tabel 1.

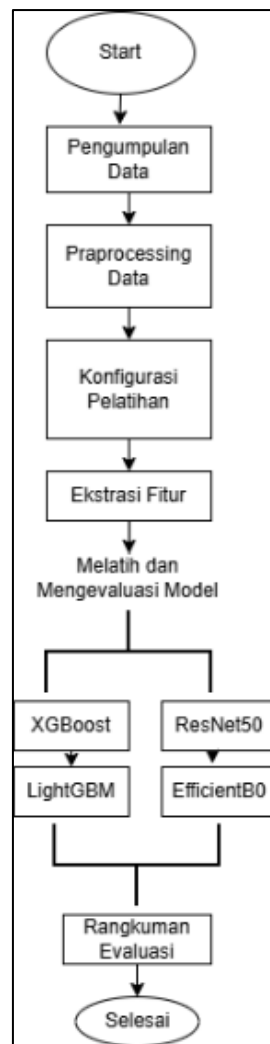
**Tabel 1.** Resolusi Input pada Model EfficientNet-B0 s.d. B7.

| Model | Resolusi Input |
|-------|----------------|
| B0    | 224 piksel     |
| B1    | 240 piksel     |
| B2    | 260 piksel     |
| B3    | 300 piksel     |
| B4    | 380 piksel     |
| B5    | 456 piksel     |
| B6    | 528 piksel     |
| B7    | 600 piksel     |

## 3. HASIL DAN PEMBAHASAN

### Alur Penelitian

Gambar 3 memperlihatkan alur penelitian mulai dari pengumpulan dan pra-pemrosesan citra Batik Lasem, penentuan konfigurasi pelatihan, serta ekstraksi fitur untuk model boosting dan CNN. Data yang telah diproses kemudian digunakan untuk melatih dan mengevaluasi keempat model, sebelum hasil akhirnya dirangkum untuk menentukan model terbaik.



**Gambar 3.** Alur Penelitian.

### Dataset

Dataset yang digunakan dalam penelitian ini berasal dari Mendeley Data dengan judul “Batik Lasem Motifs Collection”. Kumpulan data ini berisi citra digital dari lima motif Batik Lasem yang memiliki karakter visual berbeda, yaitu Gunung Ringgit, Kricak/Watu Pecah, Latohan, Nyuk Pitu, dan Seritan. Setiap motif menampilkan pola ornamentik khas Batik Lasem yang merepresentasikan pengaruh budaya Jawa Tionghoa. Total keseluruhan citra dalam dataset ini berjumlah 5.879 gambar, dengan distribusi seperti ditunjukkan pada Tabel 2.

**Tabel 2.** Ringkasan Dataset Motif Batik Lasem.

| <b>Motif Batik Lasem</b> | <b>Jumlah Citra</b> |
|--------------------------|---------------------|
| Gunung Ringgit           | 874                 |
| Kricak / Watu Pecah      | 1.005               |
| Latohan                  | 1.379               |
| Nyuk Pitu                | 1.292               |
| Seritan                  | 1.329               |
| <b>Total</b>             | <b>5.879</b>        |

Dataset ini digunakan sebagai sumber utama dalam proses pelatihan, validasi, dan evaluasi model. Seluruh citra kemudian melalui tahapan prapemrosesan seperti resizing, normalization, untuk memastikan kualitas dan konsistensi data selama eksperimen. Dataset dapat diakses melalui tautan "[Dataset Batik Lasem](#)"

### Pengumpulan Data

Teknik pengumpulan data pada penelitian ini memanfaatkan sumber sekunder dari Mendeley Data melalui repositori *Batik Lasem Motifs Collection*. Seluruh citra lima motif Batik Lasem Gunung Ringgit, Kricak/Watu Pecah, Latohan, Nyuk Pitu, dan Seritan diunduh lalu diunggah ke Google Colab untuk diekstraksi dan disusun ulang ke dalam folder sesuai label. Penataan ini memastikan setiap citra berada pada kelas yang tepat dan siap untuk tahap pemrosesan serta analisis. Pemanfaatan dataset daring memungkinkan penelitian memperoleh data yang rapi, relevan, dan dilengkapi metadata tanpa perlu pengambilan gambar secara langsung.

### Pra-pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk memastikan seluruh citra berada dalam kondisi yang konsisten sebelum digunakan dalam proses pelatihan model. Langkah ini meliputi penyalarsan ukuran gambar, normalisasi nilai piksel, serta pengecekan kecocokan antara citra dan label kelasnya.

Proses dimulai dengan memanfaatkan ImageDataGenerator untuk menormalkan nilai piksel citra menjadi rentang 0–1 melalui rescaling sebesar  $1/255$ . Normalisasi ini membantu mempercepat proses pelatihan dan menjaga kestabilan performa model, terutama pada algoritma berbasis deep learning. Setelah itu, seluruh citra dimuat ke dalam memori dengan ukuran seragam  $224 \times 224$  piksel menggunakan proses batch loading.



**Gambar 4.** Pra-pemrosesan Data.

Pendekatan ini digunakan agar pemuatan citra tetap efisien dan tidak membebani kapasitas memori. Setiap batch yang berhasil diproses kemudian digabungkan ke dalam array utama (`X_images`), sementara label setiap citra diubah menjadi bentuk numerik yang disimpan dalam `y_labels_encoded`. Tahap berikutnya adalah melakukan visualisasi contoh citra dari masing-masing kelas motif Gunung Ringgit, Kricak/Watu Pecah, Latohan, Nyuk Pitu, dan

Seritan. Visualisasi ini berfungsi sebagai pemeriksaan awal untuk memastikan bahwa gambar telah terbaca dengan benar, ukurannya seragam, dan labelnya sesuai dengan kelas yang seharusnya.

Secara keseluruhan, proses pra-pemrosesan ini memastikan dataset siap digunakan pada tahap pelatihan model. Penyelarasan ukuran, normalisasi piksel, dan pengecekan visual menjadi langkah penting untuk meminimalkan kesalahan dan meningkatkan efektivitas model dalam mengenali motif Batik Lasem.

### **Ekstraksi Fitur**

Tahap ekstraksi fitur bertujuan mengubah citra yang telah diproses menjadi bentuk representasi numerik yang dapat diolah oleh algoritma *machine learning*. Dalam penelitian ini, proses tersebut dilakukan menggunakan arsitektur EfficientNetB0 sebagai feature extractor (Burhanuddin et al., 2025). Model ini dipilih karena kemampuan konvolusinya yang efektif dalam menangkap pola visual dan telah melalui pelatihan awal (*pretrained*) pada dataset ImageNet. Pada prosesnya, EfficientNetB0 dimuat tanpa lapisan klasifikasi atas (`include_top=False`) sehingga model hanya berfungsi untuk mengekstraksi karakteristik visual seperti tekstur, bentuk, dan pola motif. Seluruh bobot jaringan kemudian dibekukan (`trainable=False`) agar fitur yang sudah dipelajari tetap konsisten. Tahap berikutnya adalah penerapan GlobalAveragePooling2D untuk merangkum keluaran fitur menjadi vektor satu dimensi yang lebih kompak namun tetap informatif. Setelah arsitektur ekstraktor fitur siap, seluruh citra dalam dataset diproses melalui model tersebut untuk menghasilkan matriks fitur (`X_features`). Representasi fitur inilah yang selanjutnya digunakan sebagai masukan bagi algoritma machine learning klasik seperti SVM dan Random Forest.

### **Konfigurasi Pelatihan Model**

Konfigurasi pelatihan model dalam penelitian ini mencakup pengaturan arsitektur, parameter pelatihan, dan skema evaluasi. Untuk model *deep learning*, ResNet50 dan EfficientNetB0 digunakan sebagai feature extractor dengan bobot pretrained ImageNet yang dibekukan. Lapisan tambahan berupa GlobalAveragePooling2D dan Dense softmax ditambahkan untuk proses klasifikasi.

Model dikompilasi menggunakan optimizer Adam (`lr=0.001`) dan fungsi loss `sparse_categorical_crossentropy`, dengan batch size 32 dan 10 epoch. Dua callback diterapkan, yaitu `EarlyStopping` untuk mencegah overfitting dan `ReduceLROnPlateau` untuk menyesuaikan laju pembelajaran ketika performa validasi menurun. Proses evaluasi menggunakan Stratified K-Fold (`k=5`) agar distribusi kelas tetap seimbang di setiap fold. Pada setiap fold, model dilatih ulang dan dievaluasi menggunakan akurasi, presisi, recall, serta F1-

score. Semua prediksi agregat kemudian digunakan untuk membangun confusion matrix sebagai gambaran performa keseluruhan.

### Evaluasi Model

Evaluasi model dilakukan dengan memanfaatkan empat indikator utama, yaitu akurasi, presisi, recall, dan F1-score. Selain itu, proses evaluasi dilakukan menggunakan skema k-fold cross validation dengan nilai  $k = 5$ , sehingga performa setiap model dapat diuji secara lebih konsisten dan tidak bergantung pada satu pembagian data saja. Keempat metrik tersebut digunakan untuk mengukur sejauh mana model mampu melakukan evaluasi model klasifikasi motif batik lasem.

#### Akurasi (Accuracy)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

#### Presisi (Precision)

$$Precision = \frac{TP}{TP + FP} \quad (8)$$

#### Recall (Sensitivity atau True Positive Rate)

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

#### F1-Score

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (10)$$


### Hasil Klasifikasi LightGBM

Model XGBoost menunjukkan performa yang sangat baik dalam mengklasifikasikan motif Batik Lasem. Nilai rata-rata akurasi mencapai 0.9611, dengan precision, recall, dan F1-score yang konsisten tinggi pada rentang 0.9611–0.9615 dapat dilihat pada tabel 3.

**Tabel 3.** Hasil LightGBM.

| Eksperimen Fold  | Accuracy      | Precision     | Recall        | F1-score      |
|------------------|---------------|---------------|---------------|---------------|
| 1                | 0.9650        | 0.9651        | 0.9650        | 0.9650        |
| 2                | 0.9650        | 0.9652        | 0.9650        | 0.9651        |
| 3                | 0.9642        | 0.9645        | 0.9642        | 0.9641        |
| 4                | 0.9573        | 0.9579        | 0.9573        | 0.9574        |
| 5                | 0.9539        | 0.9546        | 0.9539        | 0.9540        |
| <b>Rata-rata</b> | <b>0.9611</b> | <b>0.9615</b> | <b>0.9611</b> | <b>0.9611</b> |

Confusion matrix memperlihatkan gambar 6 bahwa sebagian besar sampel pada tiap kelas berhasil diprediksi dengan benar, terutama pada kelas seperti Latohan dan Gunung Ringgit yang memiliki tingkat keberhasilan prediksi sangat tinggi. Kesalahan klasifikasi yang terjadi relatif kecil dan tidak berdampak signifikan pada performa keseluruhan model.



**Gambar 5.** Confusion Matrix LightGBM.


### Hasil Klasifikasi XGBoost

Model XGBoost tabel 4 menunjukkan performa klasifikasi yang sangat baik dan stabil pada seluruh eksperimen K-Fold, dengan rata-rata akurasi sebesar 0.9556. Nilai precision, recall, dan F1-score juga konsisten berada di kisaran 0.955–0.956, menandakan kemampuan model yang seimbang dalam mengenali seluruh kelas motif Batik Lasem.

**Tabel 4.** Hasil XGBoost.

| Eksperimen Fold  | Accuracy      | Precision     | Recall        | F1-score      |
|------------------|---------------|---------------|---------------|---------------|
| 1                | 0.9565        | 0.9568        | 0.9565        | 0.9566        |
| 2                | 0.9599        | 0.9601        | 0.9599        | 0.9600        |
| 3                | 0.9590        | 0.9590        | 0.9590        | 0.9590        |
| 4                | 0.9514        | 0.9519        | 0.9514        | 0.9515        |
| 5                | 0.9514        | 0.9519        | 0.9514        | 0.9513        |
| <b>Rata-rata</b> | <b>0.9556</b> | <b>0.9560</b> | <b>0.9556</b> | <b>0.9557</b> |

Model XGBoost menunjukkan kemampuan klasifikasi yang sangat baik, terlihat dari banyaknya prediksi benar pada diagonal confusion matrix gambar 7. Kesalahan antar kelas sangat minimal, menandakan model mampu membedakan setiap motif Batik Lasem dengan konsisten dan akurat.



Gambar 6. Confusion Matrix XGBoost.


### Hasil Klasifikasi ResNet50

Model ResNet50 menunjukkan performa yang cukup baik dengan rata-rata akurasi 0.9029 serta precision, recall, dan F1-score yang konsisten di kisaran 0.90 dapat dilihat pada tabel 5.

Tabel 5. Hasil ResNet50.

| Eksperimen Fold  | Accuracy      | Precision     | Recall        | F1-score      |
|------------------|---------------|---------------|---------------|---------------|
| 1                | 0.8959        | 0.8958        | 0.8959        | 0.8956        |
| 2                | 0.8942        | 0.8988        | 0.8942        | 0.8947        |
| 3                | 0.9027        | 0.9060        | 0.9027        | 0.9036        |
| 4                | 0.9189        | 0.9201        | 0.9189        | 0.9186        |
| 5                | 0.9027        | 0.9025        | 0.9027        | 0.9024        |
| <b>Rata-rata</b> | <b>0.9029</b> | <b>0.9047</b> | <b>0.9029</b> | <b>0.9030</b> |

Hasil confusion matrix memperlihatkan gambar 8 bahwa sebagian besar kelas dapat diprediksi dengan benar, terutama pada kelas Kricak Watu Pecah dan Seritan yang memiliki jumlah prediksi akurat tinggi.



Gambar 7. Confusion Matrix ResNet50.


## Hasil Klasifikasi EfficientNetB0

Model EfficientNetB0 menunjukkan performa yang sangat rendah berdasarkan hasil evaluasi menggunakan metrik akurasi, precision, recall, dan F1-score. Rata-rata akurasi hanya mencapai 0.2343, sementara precision berada pada 0.0549 dan F1-score hanya 0.0890. Nilai yang sangat kecil ini mengindikasikan bahwa model gagal mempelajari pola visual motif Batik Lasem secara efektif dan menghasilkan prediksi yang mendekati *random guessing*.

**Tabel 6.** Hasil EfficientNetB0.

| Eksperimen Fold  | Accuracy      | Precision     | Recall        | F1-score      |
|------------------|---------------|---------------|---------------|---------------|
| 1                | 0.2346        | 0.0551        | 0.2346        | 0.0892        |
| 2                | 0.2338        | 0.0547        | 0.2338        | 0.0886        |
| 3                | 0.2338        | 0.0547        | 0.2338        | 0.0886        |
| 4                | 0.2346        | 0.0551        | 0.2346        | 0.0892        |
| 5                | 0.2346        | 0.0551        | 0.2346        | 0.0892        |
| <b>Rata-rata</b> | <b>0.2343</b> | <b>0.0549</b> | <b>0.2343</b> | <b>0.0890</b> |

Hasil tersebut juga tercermin pada confusion matrix gambar 9, di mana EfficientNetB0 cenderung memprediksi hampir semua sampel ke satu kelas dominan. Hampir tidak ada kelas yang berhasil dikenali dengan benar, menunjukkan bahwa model tidak mampu membedakan fitur antar motif.



**Gambar 8.** Confusion Matrix EfficientNetB0.

## Pembahasan

Hasil penelitian menunjukkan adanya perbedaan performa yang cukup signifikan antara model berbasis *machine learning* klasik (LightGBM dan XGBoost) dengan model *deep learning* (ResNet50 dan EfficientNetB0) dalam mengklasifikasikan motif Batik Lasem. Perbedaan ini dapat dianalisis dari aspek karakteristik data, metode ekstraksi fitur, serta konfigurasi pelatihan yang digunakan.

Model LightGBM dan XGBoost terbukti memberikan performa terbaik dengan rata-rata akurasi masing-masing sebesar 0.9611 dan 0.9556. Tingginya nilai tersebut menunjukkan bahwa kedua model mampu memanfaatkan fitur hasil ekstraksi dari EfficientNetB0 secara optimal. Hal ini disebabkan karena algoritma boosting memiliki keunggulan dalam menangani data dengan dimensi tinggi serta mampu meminimalkan kesalahan secara iteratif melalui pembentukan *weak learners*. Selain itu, kestabilan nilai precision, recall, dan F1-score pada kedua model menunjukkan bahwa tidak terjadi ketimpangan prediksi antar kelas, sehingga model dapat mengenali kelima motif Batik Lasem secara seimbang.

Sebaliknya, model ResNet50 sebagai representasi *deep learning* menunjukkan performa yang cukup baik dengan rata-rata akurasi sebesar 0.9029. Meskipun tidak sebaik model boosting, hasil ini tetap menunjukkan bahwa ResNet50 mampu menangkap pola visual dari citra batik dengan cukup efektif. Hal ini dapat disebabkan oleh kemampuan arsitektur ResNet dalam mengatasi permasalahan *vanishing gradient* melalui konsep residual learning, sehingga proses pelatihan menjadi lebih stabil. Namun demikian, performanya yang lebih rendah dibandingkan model boosting mengindikasikan bahwa pendekatan *end-to-end learning* pada dataset ini belum sepenuhnya optimal, kemungkinan karena jumlah data yang terbatas atau kurangnya proses *fine-tuning* pada lapisan jaringan.

Berbeda dengan ketiga model lainnya, EfficientNetB0 justru menunjukkan performa yang sangat rendah dengan akurasi hanya sebesar 0.2343. Hasil ini mengindikasikan bahwa model gagal dalam mempelajari representasi fitur yang relevan untuk membedakan motif Batik Lasem. Fenomena ini dapat disebabkan oleh beberapa faktor, antara lain pembekuan seluruh lapisan (*freeze layer*) sehingga model tidak dapat beradaptasi dengan karakteristik dataset, kurangnya proses pelatihan lanjutan (*fine-tuning*), serta kemungkinan ketidaksesuaian distribusi fitur antara dataset ImageNet dengan citra batik. Selain itu, nilai akurasi yang mendekati 0.20–0.25 menunjukkan bahwa model cenderung melakukan *random guessing* atau hanya memprediksi satu kelas dominan, sebagaimana terlihat pada confusion matrix.

Jika dibandingkan secara keseluruhan, hasil penelitian ini menunjukkan bahwa kombinasi ekstraksi fitur menggunakan CNN (EfficientNetB0) dengan klasifikasi menggunakan algoritma boosting (LightGBM dan XGBoost) merupakan pendekatan yang paling efektif. Strategi ini mampu menggabungkan keunggulan CNN dalam menangkap fitur visual kompleks dengan kekuatan boosting dalam melakukan klasifikasi berbasis fitur numerik.

Selain itu, penggunaan metode evaluasi Stratified K-Fold ( $k=5$ ) memberikan validasi yang lebih kuat terhadap hasil penelitian, karena setiap model diuji pada berbagai pembagian data dengan distribusi kelas yang seimbang. Hal ini meningkatkan reliabilitas hasil dan mengurangi potensi bias dalam evaluasi.

Secara keseluruhan, penelitian ini menegaskan bahwa pemilihan model dan strategi pelatihan memiliki pengaruh yang sangat besar terhadap performa klasifikasi citra. Untuk penelitian selanjutnya, disarankan melakukan *fine-tuning* pada model deep learning, menambah jumlah data, serta mengeksplorasi teknik augmentasi citra agar performa model seperti EfficientNetB0 dan ResNet50 dapat ditingkatkan dan lebih kompetitif dibandingkan model boosting.

#### **4. KESIMPULAN DAN SARAN**

Berdasarkan hasil pengujian yang dilakukan menggunakan empat model klasifikasi LightGBM, XGBoost, ResNet50, dan EfficientNetB0 dapat disimpulkan bahwa LightGBM merupakan model dengan performa terbaik dalam mengklasifikasikan motif Batik Lasem, dengan rata-rata akurasi mencapai 0.9611 serta nilai precision, recall, dan F1-score yang konsisten tinggi. XGBoost menyusul dengan akurasi 0.9556 dan stabilitas metrik yang serupa, sehingga memperlihatkan bahwa metode boosting berbasis fitur tekstur sangat efektif dalam mengenali pola visual Batik Lasem. Model ResNet50 juga menunjukkan performa yang cukup baik dengan akurasi rata-rata 0.9029, menandakan bahwa arsitektur residual dapat mengekstraksi pola tekstur dan bentuk batik secara mendalam. Sebaliknya, EfficientNetB0 memberikan performa rendah dengan akurasi hanya 0.2343, yang mengindikasikan bahwa model ini belum mampu mempelajari karakteristik visual Batik Lasem secara optimal, kemungkinan akibat kapasitas model yang terlalu kecil, kurangnya augmentasi data, atau pengaturan hyperparameter yang belum sesuai. Secara keseluruhan, penelitian ini menunjukkan bahwa pendekatan berbasis boosting lebih unggul dalam menangani dataset Batik Lasem dibandingkan model deep learning murni tanpa optimasi tambahan. Penelitian selanjutnya disarankan untuk melakukan peningkatan strategi augmentasi data serta memperluas jumlah dan variasi citra Batik Lasem untuk meningkatkan kemampuan generalisasi model. Selain itu, eksplorasi arsitektur deep learning yang lebih modern seperti EfficientNetV2, ConvNeXt, atau Vision Transformer dapat dilakukan untuk mengetahui apakah model tersebut lebih mampu menangkap kompleksitas motif batik. Penelitian berikutnya juga perlu melakukan tuning hyperparameter yang lebih mendalam pada EfficientNetB0 agar performanya meningkat secara signifikan. Implementasi sistem berbasis

web atau mobile menggunakan model terbaik dari penelitian ini juga dapat menjadi langkah lanjutan untuk mendukung pelestarian dan digitalisasi Batik Lasem, sekaligus menyediakan alat bantu identifikasi bagi masyarakat dan pelaku industri batik.

## DAFTAR REFERENSI

- Akbar, N. A., Sunyoto, A., Arief, M. R., & Caesarendra, W. (2020). Improvement of decision tree classifier accuracy for healthcare insurance fraud prediction by using extreme gradient boosting algorithm. In *2020 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)* (pp. 110–114). <https://doi.org/10.1109/ICIMCIS51567.2020.9354286>
- Alqahtani, M., Mathkour, H., & Ben Ismail, M. M. (2020). IoT botnet attack detection based on optimized extreme gradient boosting and feature selection. *Sensors*, *20*(21), 6336. <https://doi.org/10.3390/s20216336>
- Aqsha, D. (2024). Klasifikasi tweet yang mengandung ujaran kebencian dengan XGBoost dan logistic regression. *Jurnal Komputer dan Informatika*, *19*(1), 64–72.
- Burhanuddin, M. I., Syaifullah, A., Jaya, S. A. P., & Somoal, M. G. (2025). Analisis komparatif model MobileNetV1 dan EfficientNetB0 dalam klasifikasi citra empat musim menggunakan transfer learning. *JEKIN: Jurnal Teknik Informatika*, *5*(2), 508–521. <https://doi.org/10.58794/jekin.v5i2.1378>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). <https://doi.org/10.1145/2939672.2939785>
- Danang, D., & Mustofa, Z. (2026). CLSTMNet architecture: A CNN–LSTM-based hybrid deep learning model for DDoS attack detection and mitigation in network security. *Journal of Artificial Intelligence and Technology*.
- Fahmi, A., Hafidz, A., Puspaningrum, E. Y., & Nurlaili, A. L. (2025). Penerapan LightGBM menggunakan ekstraksi fitur ruang warna HSV untuk klasifikasi rempah rimpang. *JATI (Jurnal Mahasiswa Teknik Informatika)*, *9*(3), 5492–5498.
- Hafidza, S. P. R. (2025). Study of the process and aesthetics of Lasem batik motifs in the “Kidang Mas” business unit, Rembang Regency. *Eduarts: Jurnal Pendidikan Seni*, *14*(2), 42–57. <https://doi.org/10.15294/eduarts.v14i2.11295>

- Handhayani, T., Hendryli, J., & Hiryanto, L. (2017). Comparison of shallow and deep learning models for classification of Lasem batik patterns. In *2017 1st International Conference on Informatics and Computational Sciences (ICICoS)* (pp. 11–16). <https://doi.org/10.1109/ICICOS.2017.8276330>
- Hardi, N. (2021). *Klasifikasi jenis batik menggunakan deep convolutional neural network* (Skripsi). Universitas Nusa Mandiri.
- Haryani, T. (2023). *Perlindungan hukum terhadap hak cipta batik Lasem* (Skripsi). Universitas Islam Sultan Agung.
- Immanuel, J. P., & Handhayani, T. (2025). Prediksi harga pangan Jayapura menggunakan ELM, LSTM, LightGBM, dan GB. *Jurnal Ilmu Komputer dan Sistem Informasi*, 13(2). <https://doi.org/10.24912/jiksi.v13i2.35122>
- Jaeni, M., Hidayati, N., & Idris, S. (2024). Laseman hand-drawn batik motifs and socio-religious life patterns of the Lasem community. *El Harakah: Jurnal Budaya Islam*, 26(1), 204–226. <https://doi.org/10.18860/eh.v26i1.26617>
- Maghfiroh, Q., & Umami, S. (2022). Visualisasi motif kricak/watu pecah di perusahaan batik tulis Lasem. *Jurnal Desain*, 9(3), 459–468. <https://doi.org/10.30998/jd.v9i3.12999>
- Nastitie, C., & Irma. (2025). Perbandingan metode MobileNetV2 dan EfficientNetB0 untuk klasifikasi jenis pisang. *INTECOMS: Journal of Information Technology and Computer Science*, 8(6), 1990–1999. <https://doi.org/10.31539/0240cx09>
- Prasetyo, D., & Disarifianti, N. (2021). Studi pengembangan desain motif batik tulis Lasem Rembang. In *Prosiding Seminar Nasional Desain Komunikasi Visual* (Vol. 1, pp. 14–25).
- Rahman, I. F., Al Azies, H., & Akrom, M. (2025). Deteksi struktur material perovskit ABO<sub>3</sub> berbasis machine learning. *METIK*, 9(1), 137–147. <https://doi.org/10.47002/metik.v9i1.1036>
- Sihabillah, A., Tholib, A., & Basit, I. (2025). Optimasi model ResNet50 untuk klasifikasi sampah. *Indexia*, 6, 102. <https://doi.org/10.30587/indexia.v6i2.9342>
- Siswanto, E., Danang, D., Kusumaningroem, I., & Akhsani, I. (2026). Assessing software architecture resilience using quantitative metrics in cloud native application development environments. *Indonesian Journal of Informatics*, 1(1), 11–21.
- Sofiani, S., Yulius, K. G., & Hardjasa, G. E. (2025). Potensi batik Lasem sebagai daya tarik wisata. *JHIP: Jurnal Ilmiah Ilmu Pendidikan*, 8(9), 10518–10522. <https://doi.org/10.54371/jiip.v8i9.9042>

- Stanley, J., Lubis, C., & Handhayani, T. (2022). Sistem pengenalan COVID-19 berdasarkan foto X-ray paru dengan metode EfficientNet-B0. *Jurnal Ilmu Komputer dan Sistem Informasi*, 10(2).
- Wang, Y., & Wang, T. (2020). Application of improved LightGBM model in blood glucose prediction. *Applied Sciences*, 10(9), 3227. <https://doi.org/10.3390/app10093227>
- Wang, Y., Chen, J., Chen, X., Zeng, X., Kong, Y., Sun, S., Guo, Y., & Liu, Y. (2020). Short-term load forecasting for industrial customers based on TCN-LightGBM. *IEEE Transactions on Power Systems*, 36(3), 1984–1997. <https://doi.org/10.1109/TPWRS.2020.3028133>
- Wardana, B. K., Rachmawati, E., & Wirayuda, T. A. B. (2021). Pengenalan gestur tangan statis menggunakan CNN dengan arsitektur EfficientNet-B4. *EProceedings of Engineering*, 8(2).
- Wijaya, A. (2023). Pengenalan aktivitas manusia dengan metode ResNet50 dan VGG16. *Jurnal Komputer dan Informatika*, 18(1), 9–17. <https://doi.org/10.24912/jiksi.v10i2.22549>
- William. (2025). Perbandingan kinerja metode klasifikasi untuk memprediksi putus sekolah dan keberhasilan akademik siswa. *Jurnal Ilmu Komputer dan Sistem Informasi*, 13(1), 1–6.
- Yan, Z., & Wen, H. (2021). Electricity theft detection based on extreme gradient boosting in AMI. *IEEE Transactions on Instrumentation and Measurement*, 70, 1–9. <https://doi.org/10.1109/TIM.2020.3048784>