

Classification of Indonesian Batik Patterns Using Convolutional Neural Network with MobileNetV3 Architecture

Aldi Ardiansyah^{1*)}, Tinaliah²⁾

¹⁾²⁾Informatika, Ilmu Komputer dan Rekayasa, Universitas Multi Data Palembang

*) Correspondence author: Aldi Ardiansyah, aldiardiansyah_2226250059@mhs.mdp.ac.id,
Palembang, Indonesia

DOI : <https://doi.org/10.37012/jtik.v12i1.3205>

Abstract

Indonesia has a diversity of ethnic groups that give rise to cultural richness, one of which is batik as a national identity. According to the Great Dictionary of the Indonesian Language, batik is a patterned cloth made by applying wax onto the fabric and processed in a certain way. Batik is an Indonesian cultural heritage with a variety of motifs that reflect regional identity and philosophical values. However, public understanding of the range of motifs is still limited, so technological support is needed for automatic identification. Although batik has become a symbol of national culture, the public's knowledge about the types and meanings of its motifs remains limited. This study develops a system for classifying Indonesian batik motifs using a Convolutional Neural Network with MobileNetV3 Small, MobileNetV3 Large, and MobileNetV2 architectures based on transfer learning. The dataset consists of 3,000 batik images with 20 motif classes from public sources, processed through image resizing to 224×224 pixels, augmentation (rotation, flip, zoom, and random brightness), and splitting into training, validation, and test sets with proportions of 80%, 10%, and 10%. Evaluation was conducted using accuracy, precision, recall, and F1 score. The results showed that all architectures achieved accuracy above 88%, with the best values exceeding 99%. MobileNetV3 Large consistently maintained accuracy up to 99% in several configurations and proved to be the most stable architecture, whereas MobileNetV2 reached a maximum accuracy of 99.33% at a learning rate of 0.0001. Therefore, MobileNetV3 Large is recommended as the primary architecture for batik motif recognition applications.

Keywords: Indonesian Batik, Batik Motif Classification, Convolutional Neural Network, MobileNetV3.

Abstrak

Indonesia memiliki keberagaman suku bangsa yang melahirkan kekayaan budaya, salah satunya batik sebagai identitas nasional. Menurut Kamus Besar Bahasa Indonesia, batik adalah kain bergambar yang dibuat dengan menerakan malam pada kain dan diproses dengan cara tertentu. Batik merupakan warisan budaya Indonesia dengan keragaman motif yang mencerminkan identitas dan nilai filosofis daerah, namun pemahaman masyarakat terhadap ragam motifnya masih terbatas sehingga diperlukan dukungan teknologi untuk identifikasi otomatis. Meskipun batik telah menjadi simbol budaya bangsa, pengetahuan masyarakat mengenai ragam dan makna motif masih terbatas. Penelitian ini mengembangkan sistem klasifikasi motif batik Indonesia menggunakan Convolutional Neural Network dengan arsitektur MobileNetV3 Small, MobileNetV3 Large, dan MobileNetV2 berbasis transfer learning. Dataset terdiri dari 3.000 citra batik dengan 20 kelas motif dari sumber publik, yang diproses melalui pengubahan ukuran citra menjadi 224×224 piksel, augmentasi (rotasi, flip, zoom, dan random brightness), serta pembagian data menjadi latih, validasi, dan uji dengan proporsi 80%, 10%, dan 10%. Evaluasi menggunakan akurasi, precision, recall, dan F1 score. Hasil menunjukkan seluruh arsitektur mencapai akurasi di atas 88% dengan nilai terbaik melebihi 99%. MobileNetV3 Large secara konsisten

mempertahankan akurasi hingga 99% pada beberapa konfigurasi dan menjadi arsitektur paling stabil, sedangkan MobileNetV2 mencapai akurasi maksimum 99,33% pada learning rate 0,0001. Oleh karena itu, MobileNetV3 Large direkomendasikan sebagai arsitektur utama untuk aplikasi pengenalan motif batik.

Kata Kunci : *Batik Indonesia, Klasifikasi Motif Batik, Convolutional Neural Network, MobileNetV3-Large*

PENDAHULUAN

Indonesia memiliki keberagaman suku bangsa yang melahirkan kekayaan budaya, salah satunya batik sebagai identitas nasional. Menurut Kamus Besar Bahasa Indonesia, batik adalah kain bergambar yang dibuat dengan menerakan malam pada kain dan diproses dengan cara tertentu. Batik diakui oleh UNESCO sebagai warisan budaya dunia sejak 2 Oktober 2009 (Afifah & Lusiana, 2025) dan dianggap sebagai bagian penting dari peradaban manusia (Anastasya et al., 2024). Dalam seni rupa, batik dipandang sebagai lukisan dua dimensi dengan nilai estetika dan filosofis tinggi yang menggambarkan animisme dan dinamisme (Nur Ramadhan et al., 2024).

Meskipun batik telah menjadi simbol budaya bangsa, pengetahuan masyarakat mengenai ragam dan makna motif masih terbatas. Setiap motif batik mengandung nilai dan filosofi yang mencerminkan identitas serta kearifan lokal, namun pemahaman terhadap karakteristiknya umumnya hanya dimiliki oleh pengrajin batik (Ridwan Wibisono et al., 2025). Rendahnya literasi budaya berakibat pada penurunan minat generasi muda terhadap batik dan berkurangnya jumlah perajin aktif dari 151.565 menjadi sekitar 37.914 orang berdasarkan data APPBI (2020) (Ridwan Wibisono et al., 2025). Kondisi ini menunjukkan pentingnya upaya pelestarian melalui pendekatan modern berbasis teknologi.

Dalam konteks tersebut, Convolutional Neural Network (CNN) dapat digunakan untuk klasifikasi motif batik karena kemampuannya mengekstraksi fitur visual seperti pola, garis, tekstur, dan warna secara otomatis (Darma Ananda et al., 2025). Selain itu, kelebihan CNN terletak pada kedalaman jaringan yang tinggi yang menjadikannya metode ini sangat unik untuk digunakan pada data citra (Tinaliah, 2023). Beberapa penelitian terdahulu menunjukkan efektivitas CNN. (Afifah & Lusiana, 2025) memperoleh akurasi 75% untuk klasifikasi tiga motif batik Semarang. (Anastasya et al., 2024) mendapatkan akurasi 79,62% pada data uji menggunakan EfficientNet-B0. Sastypratiwi & Muhardi (2024)

mencapai akurasi 91,25% dengan MobileNet dan 100% pada MobileNet+FineTuning. Sementara itu, (Puspita Sari & Elvitaria, 2025) melaporkan akurasi 93,42% untuk pelatihan dan 93,53% untuk pengujian dengan MobileNetV3-Large.

Salah satu arsitektur CNN yang dirancang untuk efisiensi dan performa tinggi adalah MobileNetV3, yang merupakan pengembangan dari MobileNetV1 dan MobileNetV2. MobileNetV3 mengintegrasikan depthwise separable convolution, inverted residual block, squeeze-and-excitation, serta fungsi aktivasi hard-swish untuk meningkatkan efisiensi komputasi tanpa mengorbankan akurasi. MobileNetV3 memiliki dua varian utama, yaitu MobileNetV3-Small yang dioptimalkan untuk perangkat dengan sumber daya terbatas, dan MobileNetV3-Large yang menawarkan performa lebih tinggi dengan kompleksitas model yang lebih besar.

Meskipun MobileNet telah banyak digunakan dalam klasifikasi motif batik, sebagian besar penelitian hanya mengevaluasi satu varian arsitektur dan berfokus pada nilai akurasi akhir. Analisis mendalam terhadap stabilitas pelatihan, pola konvergensi kurva akurasi dan loss, serta sensitivitas terhadap variasi hyperparameter antar varian MobileNet khususnya MobileNetV2, MobileNetV3-Small, dan MobileNetV3-Large masih sangat terbatas. Selain itu, penelitian terdahulu umumnya menggunakan jumlah kelas yang relatif kecil, sehingga performa model pada skenario klasifikasi motif batik Indonesia dengan jumlah kelas yang besar belum banyak dieksplorasi


Oleh karena itu, penelitian ini bertujuan untuk melakukan evaluasi komprehensif dan perbandingan stabilitas performa MobileNetV3-Small, MobileNetV3-Large, dan MobileNetV2 dalam klasifikasi motif batik Indonesia. Evaluasi dilakukan melalui eksplorasi hyperparameter serta analisis kurva pelatihan untuk menilai tingkat konvergensi, stabilitas, dan potensi overfitting masing-masing arsitektur. Kontribusi utama penelitian ini diharapkan dapat memberikan rekomendasi arsitektur CNN yang optimal dan efisien untuk klasifikasi motif batik, sekaligus mendukung upaya pelestarian dan digitalisasi warisan budaya Indonesia di era modern.

METODE PENELITIAN

Dalam pelaksanaan penelitian ini, diterapkan perancangan metode terlebih dahulu untuk meminimalisir kesalahan dalam proses penelitian, tahapannya adalah sebagai berikut:

Pengumpulan Dataset

Pada tahapan ini dilakukan proses pengumpulan dataset berupa gambar motif batik. Gambar diambil dari dataset yang bersifat publik di Kaggle dengan nama “Dataset Batik Indonesia” berikut adalah link dari datasetnya <https://www.kaggle.com/datasets/hydiexe/dataset-fix/data>. Dataset ini berisi 3000 gambar yang dibagi menjadi 20 kategori atau class. motif batik dapat dilihat pada Gambar 1.




Gambar 1. Dataset Batik

Perancangan

Tahap perancangan sistem klasifikasi citra batik dilakukan menggunakan arsitektur MobileNetV3-Small, MobileNetV3-Large, dan MobileNetV2. Dataset batik dipersiapkan melalui tahap preprocessing dengan mengubah ukuran citra menjadi 224×224 piksel agar sesuai dengan input model. Augmentasi data seperti rotasi, flip, zoom, dan random

brightness diterapkan pada data training untuk menambah variasi data dan memperkaya karakteristik citra yang dipelajari model, sedangkan data validation dan testing digunakan dalam kondisi asli tanpa augmentasi, kemudian dataset dibagi menjadi data training (80%), testing (10%), dan validation (10%). Evaluasi performa model dilakukan menggunakan classification report dan confusion matrix untuk mengukur kemampuan klasifikasi motif batik. Alur perancangan dapat dilihat pada gambar 2.



Gambar 2. Alur Perancangan

Implementasi

Pada tahapan ini dilakukan implementasi dari model CNN dengan arsitektur MobileNetV3-Large, MobileNetV3-Small, dan MobileNetV2. Model dilatih menggunakan data latih yang telah melalui tahap preprocessing. Parameter pelatihan seperti learning rate, batch size, dan optimizer yang digunakan diatur sesuai kebutuhan untuk mendapatkan hasil yang optimal. Skenario pengujian parameter yang akan digunakan dapat dilihat pada Tabel 1.

Tabel 1. Skenario Pengujian Parameter

<i>Skenario</i>	<i>Learning Rate</i>	<i>Batch Size</i>	<i>Epoch</i>	<i>Arsitektur</i>
Skenario 1	0,001	32	50	<i>MobileNetV3-Small</i>
Skenario 2	0,001	32	100	
Skenario 3	0,0001	32	50	
Skenario 4	0,0001	32	100	
Skenario 5	0,001	16	50	
Skenario 6	0,001	16	100	
Skenario 7	0,0001	16	50	
Skenario 8	0,0001	16	100	
Skenario 9	0,001	32	50	<i>MobileNetV3-Large</i>
Skenario 10	0,001	32	100	
Skenario 11	0,0001	32	50	
Skenario 12	0,0001	32	100	
Skenario 13	0,001	16	50	
Skenario 14	0,001	16	100	
Skenario 15	0,0001	16	50	
Skenario 16	0,0001	16	100	
Skenario 17	0,001	32	50	<i>MobileNetV2</i>
Skenario 18	0,001	32	100	
Skenario 19	0,0001	32	50	
Skenario 20	0,0001	32	100	
Skenario 21	0,001	16	50	
Skenario 22	0,001	16	100	
Skenario 23	0,0001	16	50	
Skenario 24	0,0001	16	100	

Pengujian

Pada tahapan ini, sistem yang telah dibuat sebelumnya akan melakukan uji coba terhadap data uji. Setelah tahapan uji coba, hasil pengujian dihitung untuk mendapatkan tingkat keberhasilan metode yang digunakan dengan Confusion Matrix dalam menghitung nilai precision, recall, dan accuracy.

HASIL DAN PEMBAHASAN

Pada tahap ini dilakukan implementasi sistem klasifikasi citra batik menggunakan arsitektur *MobileNetV3-Small*, *MobileNetV3-Large*, dan *MobileNetV2*. Dataset batik terlebih dahulu disiapkan dan melalui tahap *preprocessing* dengan mengubah ukuran citra menjadi 224×224 piksel agar sesuai dengan input model. Augmentasi data seperti rotasi, *flip*, *zoom*, dan *random brightness* diterapkan pada data training untuk menambah variasi data dan memperkaya karakteristik citra yang dipelajari model, sedangkan data validation dan testing digunakan dalam kondisi asli tanpa augmentasi. Selanjutnya dataset dibagi menjadi data *training* (80%), *testing* (10%), dan *validation* (10%).

Pemodelan CNN memanfaatkan ketiga arsitektur sebagai *pretrained* model pada *ImageNet*. Pendekatan yang digunakan merupakan kombinasi *feature extraction* dan *fine-tuning* secara *single-phase*, dengan membekukan sebagian lapisan awal *backbone* dan menyesuaikan lapisan selanjutnya agar lebih spesifik terhadap karakteristik citra batik. Lapisan akhir dimodifikasi dengan *Global Average Pooling*, *Dropout* sebagai regularisasi, serta *output layer* dengan fungsi aktivasi *Softmax* sesuai jumlah kelas.

Evaluasi dilakukan menggunakan *confusion matrix* untuk menilai kemampuan model dalam mengenali dan mengklasifikasikan motif batik. Rancangan ini diharapkan mampu menghasilkan performa yang optimal dan membantu masyarakat dalam mengenali motif batik Indonesia.

Analisis Hasil Akurasi Skenario

Tabel 2 menyajikan hasil pengujian performa model klasifikasi motif batik pada 24 skenario eksperimen yang melibatkan variasi *learning rate*, *batch size*, dan jumlah *epoch* pada tiga arsitektur Convolutional Neural Network, yaitu *MobileNetV3-Small*,

MobileNetV3-Large, dan MobileNetV2. Evaluasi performa dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk memberikan gambaran menyeluruh terhadap kemampuan klasifikasi model.

Tabel 2. Hasil Pengujian *Skenario*

<i>Skenario</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Skenario 1	96,66%	96,88%	96,66%	96,65%
Skenario 2	96,99%	97,31%	96,99%	97,03%
Skenario 3	92,98%	93,86%	92,98%	92,79%
Skenario 4	90,64%	91,66%	90,64%	90,55%
Skenario 5	94,65%	95,28%	94,65%	94,59%
Skenario 6	96,66%	96,93%	96,66%	96,69%
Skenario 7	88,29%	88,59%	88,29%	87,71%
Skenario 8	89,97%	91,28%	89,97%	89,89%
Skenario 9	99%	99,04%	99%	99%
Skenario 10	99%	99,06%	99%	99%
Skenario 11	96,99%	97,27%	96,99%	96,98%
Skenario 12	96,32%	96,45%	96,32%	96,28%
Skenario 13	99%	99,06%	99%	99%
Skenario 14	98,33%	98,41%	98,33%	98,33%
Skenario 15	96,99%	97,12%	96,99%	96,95%
Skenario 16	98,66%	98,75%	98,66%	98,65%
Skenario 17	98,33%	98,51%	98,33%	98,33%
Skenario 18	98,66%	98,78%	98,66%	98,67%
Skenario 19	99,33%	99,37%	99,33%	99,33%
Skenario 20	99,33%	99,37%	99,33%	99,33%
Skenario 21	97,99%	98,20%	97,99%	98,02%
Skenario 22	97,99%	98,07%	97,99%	97,99%
Skenario 23	97,66%	97,81%	97,66%	97,66%
Skenario 24	99,33%	99,37%	99,33%	99,33%

Berdasarkan hasil pengujian pada 24 skenario yang melibatkan variasi *learning rate*, *batch size*, jumlah *epoch*, dan arsitektur model, diperoleh perbedaan performa yang cukup signifikan pada metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Secara umum, seluruh skenario menunjukkan performa yang baik dengan nilai akurasi di atas 88%, menandakan bahwa model mampu melakukan proses klasifikasi secara efektif.

Pada arsitektur MobileNetV3-Small (Skenario 1–8), akurasi yang diperoleh berada pada rentang 88,29% hingga 96,99%. Performa terbaik dicapai pada Skenario 2 dengan *learning rate* 0,001, *batch size* 32, dan 100 *epoch* yang menghasilkan akurasi 96,99%, sedangkan penggunaan *learning rate* 0,0001 pada beberapa skenario menyebabkan penurunan akurasi yang cukup terlihat, sehingga menunjukkan bahwa arsitektur ini lebih sensitif terhadap pemilihan hyperparameter

Pada arsitektur MobileNetV3-Large (Skenario 9–16), model mampu mempertahankan akurasi tinggi dan stabil pada berbagai konfigurasi, dengan beberapa skenario seperti Skenario 9, 10, dan 13 mencapai akurasi 99% disertai nilai precision, recall, dan F1-score yang seimbang. Pola ini menunjukkan bahwa MobileNetV3-Large memiliki kemampuan ekstraksi fitur yang baik dan generalisasi yang kuat, sehingga menjadi arsitektur yang paling stabil di antara ketiga model yang diuji.

MobileNetV2 (Skenario 17–24) menghasilkan akurasi tertinggi hingga 99,33% pada beberapa konfigurasi dengan learning rate 0,0001 dan jumlah epoch 50 maupun 100. Meskipun demikian, performa terbaik tersebut lebih dominan muncul pada kombinasi hyperparameter tertentu, sedangkan MobileNetV3-Large konsisten memberikan akurasi mendekati 99% pada lebih banyak konfigurasi. Dengan demikian, MobileNetV3-Large dapat diposisikan sebagai arsitektur utama yang direkomendasikan dalam penelitian ini karena menawarkan kombinasi akurasi tinggi dan kestabilan performa yang baik.

Analisis Akurasi Model

Tabel 3. Perbandingan Akurasi Arsitektur

<i>Learning Rate</i>	<i>Batch Size</i>	<i>Epoch</i>	<i>Model</i>		
			<i>MobileNetV3-Small</i>	<i>MobileNetV3-Large</i>	<i>MobileNetV2</i>
0,001	32	50	96,66%	99%	98,33%
0,001	32	100	96,99%	99%	98,66%
0,0001	32	50	92,98%	96,99%	99,33%
0,0001	32	100	90,64%	96,32%	99,33%
0,001	16	50	94,65%	99%	97,99%
0,001	16	100	96,66%	98,33%	97,99%
0,0001	16	50	88,29%	96,99%	97,66%
0,0001	16	100	89,97%	98,66%	99,33%

Berdasarkan perbandingan akurasi antar arsitektur CNN pada kombinasi hyperparameter yang sama sebagaimana ditunjukkan pada Tabel 3, terlihat adanya perbedaan performa yang cukup signifikan antara MobileNetV3-Small, MobileNetV3-Large, dan MobileNetV2. MobileNetV3-Small cenderung menghasilkan akurasi yang lebih

rendah dibandingkan dua arsitektur lainnya, dengan rentang akurasi antara 88,29% hingga 96,99%. Hal ini mengindikasikan bahwa MobileNetV3-Small lebih sensitif terhadap variasi learning rate dan batch size.

Pada learning rate 0,001, MobileNetV3-Large secara konsisten menunjukkan performa terbaik dibandingkan MobileNetV2, dengan akurasi mencapai 99% pada beberapa kombinasi batch size 32 maupun 16 dan jumlah epoch 25, 50, serta 100. Sebaliknya, MobileNetV2 pada konfigurasi learning rate yang sama hanya mampu mencapai akurasi maksimum sebesar 98,66%. Temuan ini menunjukkan bahwa MobileNetV3-Large memiliki kemampuan ekstraksi fitur serta kestabilan performa yang lebih baik pada pengaturan learning rate tersebut.

Meskipun demikian, MobileNetV2 tetap menunjukkan performa yang kompetitif dengan mencapai akurasi tertinggi sebesar 99,33% pada beberapa konfigurasi learning rate 0,0001. Namun, pencapaian tersebut cenderung bergantung pada kombinasi hyperparameter tertentu. Berbeda dengan MobileNetV2, MobileNetV3-Large mampu mempertahankan akurasi mendekati 99% secara lebih konsisten pada berbagai konfigurasi. Oleh karena itu, MobileNetV3-Large direkomendasikan sebagai arsitektur utama dalam penelitian ini.

Perbandingan Antar Arsitektur

Berdasarkan keseluruhan hasil eksperimen, MobileNetV3 Large dan MobileNetV2 sama-sama mampu mencapai akurasi di atas 99%, namun MobileNetV3 Large menunjukkan kestabilan performa yang lebih baik pada berbagai kombinasi hyperparameter, sehingga diposisikan sebagai arsitektur utama dalam penelitian ini. MobileNetV3 Small tetap unggul dari sisi efisiensi komputasi, tetapi akurasinya sedikit lebih rendah dan lebih sensitif terhadap variasi hyperparameter.

Perbandingan Parameter dan *FLOPs*

Selain performa klasifikasi, efisiensi komputasi juga menjadi aspek penting dalam pemilihan arsitektur *CNN*, khususnya untuk implementasi pada perangkat dengan sumber daya terbatas. Oleh karena itu, dilakukan analisis terhadap jumlah parameter dan *Floating Point Operations (FLOPs)* untuk membandingkan kompleksitas komputasi dari arsitektur

MobileNetV3-Small, *MobileNetV3-Large*, dan *MobileNetV2*. Hasil perbandingan tersebut disajikan pada Tabel 4.

Tabel 4. Perbandingan Parameter

Arsitektur	Jumlah Parameter	FLOPs
<i>MobileNetV3-Small</i>	950,660	0.1160
<i>MobileNetV3-Large</i>	3,015,572	0.4436
<i>MobileNetV2</i>	2,283,604	0,6128

Berdasarkan perbandingan parameter yang ada pada Tabel 5, *MobileNetV3-Small* memiliki jumlah parameter dan *FLOPs* paling kecil dibandingkan dua arsitektur lainnya, sehingga paling efisien secara komputasi. *MobileNetV3-Large* dan *MobileNetV2* memiliki kompleksitas komputasi yang lebih tinggi, sejalan dengan peningkatan performa klasifikasi yang diperoleh pada hasil pengujian sebelumnya. Temuan ini menunjukkan adanya *trade-off* antara efisiensi komputasi dan akurasi, di mana pemilihan arsitektur perlu disesuaikan dengan kebutuhan dan keterbatasan sumber daya system.

Implikasi Terhadap Klasifikasi Motif Batik

Hasil pengujian menunjukkan bahwa arsitektur MobileNet, khususnya *MobileNetV3-Large* dan *MobileNetV2*, sangat efektif untuk klasifikasi motif batik Indonesia dengan jumlah kelas yang besar. *MobileNetV3-Large* menonjol sebagai arsitektur utama karena mampu mempertahankan akurasi tinggi dan stabil pada berbagai kombinasi hyperparameter, sedangkan *MobileNetV2* memberikan akurasi maksimum sedikit lebih tinggi pada konfigurasi tertentu. Kombinasi akurasi tinggi, kestabilan performa, dan kompleksitas komputasi yang masih efisien menjadikan *MobileNetV3-Large* dan *MobileNetV2* layak direkomendasikan untuk implementasi sistem klasifikasi batik berbasis perangkat bergerak maupun aplikasi pelestarian budaya digital.


Analisis Kurva Loss dan Akurasi

Grafik yang ditampilkan dalam penelitian ini merupakan representasi dari konfigurasi model paling optimal untuk masing-masing arsitektur, yaitu *MobileNetV3-*

Large, *MobileNetV3-Small*, dan *MobileNetV2*. Penjelasan grafik dari masing-masing arsitektur adalah sebagai berikut.

MobileNetV3-Small


Grafik untuk *MobileNetV3-Small* dengan *learning rate* 0,001, *batch size* 16, dan 100 *epoch* yang ada pada Gambar 6 memperlihatkan penurunan *training loss* dan *validation loss* yang cukup stabil, meskipun fluktuasinya sedikit lebih besar dibandingkan *MobileNetV3-Large*. Kurva akurasi menunjukkan bahwa *training accuracy* dan *validation accuracy* meningkat hingga kisaran 96,66% dan 95,30%, yang menandakan performa klasifikasi yang baik, tetapi dengan stabilitas yang sedikit lebih rendah sehingga model lebih sensitif terhadap perubahan *hyperparameter*.



Gambar 3. *MOBILENETV3-Small Batch Size 16 LR 0.001 Epoch 100*

MobileNetV3-Large


Grafik loss dan akurasi pada konfigurasi *MobileNetV3-Large* dengan *learning rate* 0,001, *batch size* 32, dan 100 *epoch* yang dapat dilihat pada gambar 5 menunjukkan pola konvergensi yang stabil, di mana *training loss* dan *validation loss* sama-sama menurun dan kemudian mendatar pada *epoch* akhir dengan jarak yang relatif kecil. Nilai *training accuracy* dan *validation accuracy* meningkat secara konsisten hingga mencapai sekitar 99% dan 98,32%, sehingga mengindikasikan bahwa model mampu belajar dengan baik tanpa gejala *overfitting* yang signifikan dan memiliki kemampuan generalisasi yang kuat.



Gambar 4. *MOBILENETV3-Large Batch size 32 LR 0,001 Epoch 100*

MobileNetV2

Pada konfigurasi *MobileNetV2* dengan *learning rate* 0,0001, *batch size* 32, dan 100 *epoch*, yang dapat dilihat pada gambar 7, grafik loss menggambarkan penurunan *training loss* yang konsisten, sementara *validation loss* ikut menurun dan kemudian cenderung datar pada nilai yang rendah. Kurva akurasi menunjukkan *training accuracy* dan *validation accuracy* yang tinggi hingga sekitar 99,33% dan 98,66%; perbedaan keduanya sedikit lebih besar dibandingkan *MobileNetV3-Large*, sehingga meskipun akurasi yang dicapai sangat tinggi, terdapat indikasi kecenderungan *overfitting* ringan pada beberapa *epoch* akhir.



Gambar 5. *MOBILENETV2 BATCH SIZE 32 LR 0. 0001 EPOCH 100*

Kesimpulan Hasil Analisis Kurva

Berdasarkan pengamatan terhadap kurva loss dan akurasi, *MobileNetV3-Large* menunjukkan pola konvergensi yang paling stabil dengan jarak yang kecil antara *training* dan *validation*, serta akurasi validasi yang tinggi dan konsisten. *MobileNetV3-Small* memiliki performa yang cukup baik, tetapi lebih sensitif terhadap pemilihan *learning rate* dan cenderung kurang stabil pada konfigurasi tertentu. *MobileNetV2* mampu mencapai akurasi tinggi, namun beberapa konfigurasi menunjukkan indikasi *overfitting* yang lebih kuat. Dengan demikian, dari sudut pandang analisis kurva loss dan akurasi, *MobileNetV3-Large* dapat dinyatakan sebagai arsitektur yang paling baik untuk tugas klasifikasi motif batik pada penelitian ini.

KESIMPULAN DAN REKOMENDASI

Penelitian ini mengembangkan sistem klasifikasi motif batik Indonesia menggunakan Convolutional Neural Network dengan arsitektur *MobileNetV3-Small*, *MobileNetV3-Large*, dan *MobileNetV2* pada dataset berisi 3.000 citra dengan 20 kelas motif. Seluruh arsitektur mampu mencapai akurasi pengujian yang tinggi, dengan nilai terbaik melebihi 99%, sehingga ketiganya layak digunakan untuk tugas klasifikasi motif batik dengan jumlah kelas yang besar.

Berdasarkan hasil perbandingan, *MobileNetV3-Large* secara konsisten menunjukkan performa yang lebih baik dibandingkan *MobileNetV3-Small*, baik dari sisi akurasi maupun kestabilan metrik evaluasi, sehingga dapat dinyatakan sebagai varian terbaik dalam keluarga *MobileNetV3*. Jika dibandingkan dengan *MobileNetV2*, *MobileNetV3-Large* juga memberikan performa yang lebih unggul secara keseluruhan pada pengaturan *learning rate* 0,001, karena mampu mencapai akurasi hingga 99% pada berbagai kombinasi *batch size* dan *epoch*, sedangkan *MobileNetV2* pada *learning rate* yang sama hanya mencapai akurasi maksimum 98,66%. Dengan demikian, *MobileNetV3-Large* dapat disimpulkan sebagai arsitektur terbaik dan paling direkomendasikan dalam penelitian ini.

Sistem yang dikembangkan berpotensi diterapkan pada aplikasi pengenalan motif batik berbasis web maupun perangkat bergerak serta mendukung upaya pelestarian dan digitalisasi warisan budaya Indonesia. Penelitian selanjutnya disarankan untuk memperluas variasi dan jumlah dataset, menerapkan teknik augmentasi yang lebih beragam, serta mengeksplorasi arsitektur deep learning lain guna meningkatkan robustness dan kemampuan generalisasi model pada kondisi data dunia nyata.

REFERENSI

- Afifah, W. N., & Lusiana, V. (2025). KLASIFIKASI JENIS BATIK SEMARANGAN MENGGUNAKAN METODE CONVOLUTION NEURAL NETWORK (CNN). *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 10(1), 542–553. <https://doi.org/10.29100/jupi.v10i1.5873>
- Anastasya, D., Fahri, S., Situmorang, S., Ramadhani, F., & Komputer, J. I. (2024). Implementasi Metode Convolutional Neural Network (CNN) Dalam Klasifikasi Motif Batik (Vol. 18, Issue 1). <https://journal.fkom.uniku.ac.id/ilkom>
- Aras, S., & Setyanto, A. (2022). Deep Learning Untuk Klasifikasi Motif Batik Papua Menggunakan EfficientNet dan Transfer Learning. 8(1).
- Darma Ananda, T., Primajaya, A., Juardi, D., Haerul Jaman, J., & Singaperbangsa Karawang Abstract, U. (2025). Identifikasi Citra Kain Songket Pandai Sikek Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Wahana Pendidikan*, 11(7), 278–287.
- Dianda, N., Rachman, A. S., & Yadnya, S. (2025). Identifikasi Citra Motif Kain Tenun Sumbawa (Kre Alang) Menggunakan Metode Convolutional Neural Network Arsitektur MobileNetV2. *Journal of Information System Research*, 6(2), 1225–1234. <https://doi.org/10.47065/josh.v6i2.6774>
- Herawati, A. (2025). Transformasi Batik Abstrak menjadi Media Edukasi: Studi Nilai Seni dan Kreativitas pada Anomart dan Pandono Batik. *Irama: Jurnal Seni, Desain Dan Pembelajarannya*, 7(1), 25–32. <https://doi.org/10.17509/irama.v7i1.80889>

- Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., Vasudevan, V., Le, Q. V., & Adam, H. (2019). Searching for MobileNetV3. <http://arxiv.org/abs/1905.02244>
- Misela, M., Wona, A., Aulia Asyifa, S., Virgianti, R., Hamid, M. N., Handoko, I. M., Wayan, N., Septiani, P., & Lestari, M. (2023). Klasifikasi Batik Indonesia Menggunakan Convolutional Neural Network (CNN). In 172 JURTI (Vol. 7, Issue 2). <https://www.kaggle.com/datasets/dionisiusdh/indonesianbatik-motifs>.
- Nur Ramadhan, D., Aldi Erwanto, R., & Tan Enwan, R. (2024). Program Studi Teknik Informatika (Vol. 3).
- Puspita Sari, I., & Elvitaria, L. (2025). Data-driven approach for batik pattern classification using convolutional neural network (CNN). 13(3), 323–331. www.ejournal.isha.or.id/index.php/Mandiri
- Rafly Alwanda, M., Putra, R., Ramadhan, K., & Alamsyah, D. (2020). Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle. In Jurnal Algoritme (Vol. 1, Issue 1).
- Ridwan Wibisono, M., Ma'ruf Nugroho, I., Defriani, M., Informatika, T., Tinggi, S., Wastukencana, T., Cikopak, J., 53, N., Babakancikao, K., Purwakarta, K., Barat, J., & Koresponden, P. (2025). Batik Motif Classification Using CNN With Resnet-50 Architecture. In Information Systems and Technology (Vol. 6).
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2019). MobileNetV2: Inverted Residuals and Linear Bottlenecks. <http://arxiv.org/abs/1801.04381>
- Tinaliah. (2023). Klasifikasi Lesi Benign Dan Malignant Pada Rongga Mulut Menggunakan Arsitektur ResNet50 (Vol. 10, Issue 4). <http://jurnal.mdp.ac.id>