

Optimalisasi *MobileNetV2* Dalam Klasifikasi Motif Kawung dengan Menggunakan *Random Search* dan Model *Optimizer Adagrad*

Muhammad Rafli¹, Dwi Arman Prasetya², Kartika Maulida Hindrayani³

^{1,2,3}UPN "Veteran" Jawa Timur, Jl.Raya Rungkut Madya, Gunung Anyar, Surabaya, Jawa Timur, 60294

¹21083010066@student.upnjatim.ac.id

²arman.prasetya.sada@upnjatim.ac.id

³kartika.maulida.ds@upnjatim.ac.id

Corresponding author email: arman.prasetya.sada@upnjatim.ac.id

ABSTRAK

Batik merupakan warisan budaya Indonesia yang kaya akan nilai estetika dan filosofi, namun identifikasi motifnya secara manual membutuhkan keahlian khusus dan kurang efisien dalam konteks digitalisasi. Penelitian ini bertujuan mengoptimalkan arsitektur MobileNetV2 berbasis *Transfer Learning* untuk klasifikasi motif batik Kawung menggunakan metode *Random Search* dan *optimizer Adagrad*. Dataset sebanyak 658 citra motif batik Kawung dikumpulkan dari *Kaggle* dan *Google Images*, kemudian dibagi menjadi data latih (80%) dan data validasi (20%). Data diproses melalui *resizing* 224×224 piksel dan augmentasi (rotasi $\pm 20^\circ$, *horizontal flip*, *translation* 20%, *zooming* $\pm 20\%$, *brightness* $\pm 20\%$) untuk memperkaya variasi dan mengurangi *overfitting*. Model MobileNetV2 *pre-trained ImageNet* disesuaikan dengan menambahkan lapisan *Global Average Pooling*, *Batch Normalization*, *Dropout*, dan *Dense layer*. *Hyperparameter tuning* dilakukan menggunakan *Random Search* untuk mengoptimalkan *learning rate*, *batch size*, dan *dropout rate* dengan *optimizer Adagrad*. Hasil penelitian menunjukkan model mencapai akurasi validasi 96.43% dengan *precision* 0.96, *recall* 0.96, dan *F1-score* 0.96 untuk klasifikasi motif Kawung. Model konvergen pada *epoch* ke-24 dengan waktu pelatihan efisien 2.60 menit. Penelitian ini memberikan kontribusi dalam pelestarian budaya batik melalui sistem klasifikasi yang akurat, efisien, dan dapat diimplementasikan untuk digitalisasi warisan budaya Indonesia.

Keywords: Batik Kawung, *Random Search*, *Adagrad*, *Transfer Learning*, MobileNetV2

I. PENDAHULUAN

Motif Kawung merupakan salah satu batik klasik Jawa yang tetap lestari dan digunakan dalam berbagai upacara adat serta konteks budaya masyarakat hingga saat ini. Secara visual, motif ini tersusun atas bentuk oval atau elips yang berulang secara diagonal dan memiliki komposisi geometris yang stabil. Dalam tradisi Jawa, motif Kawung tidak hanya berfungsi sebagai ornamen, tetapi juga memuat nilai filosofis yang mengajarkan keseimbangan diri, pengendalian nafsu, keselarasan dengan alam, serta kesadaran spiritual manusia sebagai bagian dari tatanan kosmos yang harmonis [1]. Nilai-nilai ini menjadikan motif Kawung tidak sekadar elemen dekoratif, tetapi representasi *local wisdom* yang mengakar dan tetap relevan dalam kehidupan kontemporer.

Perkembangan teknologi *computer vision* dan *deep learning* membuka peluang baru dalam pelestarian sekaligus pengembangan motif batik melalui sistem klasifikasi citra otomatis. Dalam konteks ini, arsitektur *MobileNetV2* menjadi salah satu model yang banyak digunakan karena efisiensinya, ukuran model yang ringan, serta performanya yang tetap kompetitif dalam tugas klasifikasi visual skala besar maupun terbatas. Model ini dirancang menggunakan *inverted residuals* dan *linear bottlenecks* untuk mengurangi

kompleksitas komputasi tanpa mengorbankan akurasi, sehingga cocok diterapkan pada perangkat bertenaga rendah seperti sistem *mobile* atau *embedded devices* [2].


Meskipun demikian, performa model *MobileNetV2* sangat ditentukan oleh pemilihan *hyperparameter* yang tepat. Proses ini sering menjadi tantangan karena ruang pencarian parameter yang luas dan hubungan kompleks antarparameter. *Random Search* merupakan pendekatan eksploratif yang lebih efisien dibandingkan *Grid Search* ketika ruang *hyperparameter* besar, karena pemilihan kombinasi secara acak memberi peluang lebih tinggi untuk menemukan konfigurasi terbaik tanpa menguji seluruh kemungkinan. Di sisi lain, *Adagrad* sebagai *optimizer* adaptif mampu menyesuaikan laju pembelajaran berdasarkan frekuensi pembaruan parameter, sehingga memberikan stabilitas lebih baik terutama pada *dataset* kecil atau motif dengan kompleksitas visual yang tinggi.

Berdasarkan latar belakang tersebut, penelitian ini berfokus pada optimalisasi model *MobileNetV2* menggunakan *Random Search* dan *optimizer Adagrad* untuk meningkatkan akurasi klasifikasi motif Kawung. Pendekatan ini tidak hanya berkontribusi pada pengembangan teknologi klasifikasi citra batik, tetapi juga menjadi bagian dari upaya pelestarian motif tradisional melalui integrasi ilmu pengetahuan, kebudayaan, dan kecerdasan buatan.

II. METODOLOGI PENELITIAN

II.1 *MobileNetV2*

MobileNetV2 merupakan arsitektur *Convolutional Neural Network* (CNN) yang dirancang secara khusus untuk kebutuhan komputasi ringan dan efisien. Model ini dikembangkan untuk digunakan pada perangkat dengan sumber daya terbatas seperti *mobile devices* atau *embedded systems*, tanpa mengorbankan akurasi dalam tugas klasifikasi citra. Salah satu karakteristik utama *MobileNetV2* adalah penggunaan *depthwise separable convolution*, yaitu teknik pemisahan proses konvolusi menjadi dua tahap *depthwise convolution* dan *pointwise convolution* yang secara signifikan mengurangi jumlah parameter dan operasi komputasi dibandingkan konvolusi standar [3].



Gambar 1. Arsitektur MobileNetV2

Selain itu, *MobileNetV2* memperkenalkan konsep *inverted residuals* dan *linear bottleneck* yang berfungsi menjaga aliran informasi selama proses propagasi [4]. Struktur *inverted residual block* memungkinkan model mempertahankan fitur penting dengan cara memperluas ruang fitur terlebih dahulu kemudian memproyeksikannya kembali ke dimensi rendah. Pendekatan ini tidak hanya mengurangi kehilangan informasi, tetapi juga meningkatkan efisiensi komputasi secara keseluruhan. Penjelasan mendetail mengenai mekanisme blok ini dapat ditemukan pada dokumentasi *MobileNetV2* yang menyatakan bahwa blok residual terbalik membantu model mencapai performa tinggi dengan kompleksitas jauh lebih rendah dibandingkan CNN konvensional.

Keunggulan *MobileNetV2* menjadikannya pilihan tepat untuk klasifikasi motif batik, termasuk motif Kawung, yang memiliki pola berulang serta detail visual yang membutuhkan ekstraksi fitur secara konsisten. Struktur model yang ringan memungkinkan pelatihan dilakukan lebih cepat, sementara kemampuannya menangkap pola tekstur menjadikannya efektif untuk membedakan motif batik yang memiliki bentuk geometris mirip. Dengan demikian, *MobileNetV2* memiliki potensi besar untuk menghasilkan model klasifikasi yang efisien, akurat, dan mudah diimplementasikan dalam skala luas.

II.2 Random Search

Random Search merupakan metode *hyperparameter tuning* yang bekerja dengan memilih kombinasi parameter secara acak dari ruang pencarian yang telah ditentukan [5]. Berbeda dengan *Grid Search* yang menguji seluruh kombinasi secara menyeluruh, *Random Search* lebih efisien karena fokus eksplorasinya tersebar secara acak pada ruang parameter. Hal ini memungkinkan metode ini menemukan konfigurasi yang optimal tanpa harus melakukan evaluasi terhadap keseluruhan ruang pencarian. Studi Bergstra dan Bengio menunjukkan bahwa *Random Search* sering kali lebih efektif daripada *Grid Search*, terutama pada ruang *hyperparameter* berdimensi tinggi karena hanya sebagian kecil parameter yang benar-benar memengaruhi performa model [6]. Secara matematis, proses pemilihan *hyperparameter* terbaik pada *Random Search* dapat dinyatakan melalui persamaan:

$$h^* = \arg \min_{h \in \{h^{(1)}, h^{(2)}, \dots, h^{(n)}\}} L(f_{h^{(i)}}) \quad (1)$$

Persamaan tersebut menunjukkan bahwa solusi terbaik h^* dipilih dari himpunan kandidat *hyperparameter* $\{h^{(1)}, h^{(2)}, \dots, h^{(n)}\}$ berdasarkan nilai fungsi kerugian (*loss function*) terkecil dari model $f_{h^{(i)}}$. Dengan kata lain, *Random Search* secara acak menghasilkan kandidat parameter, melatih model, lalu memilih parameter dengan nilai *loss* paling rendah.

Keunggulan utama *Random Search* terletak pada fleksibilitas dan efisiensinya. Metode ini tidak terikat pada struktur pencarian yang kaku, sehingga mampu mengeksplorasi bagian ruang parameter yang lebih beragam. Dalam konteks klasifikasi motif Kawung, penggunaan *Random Search* sangat bermanfaat karena model *MobileNetV2* memiliki banyak parameter yang saling memengaruhi. Oleh karena itu, pendekatan acak seperti *Random Search* memberikan peluang lebih besar untuk menemukan konfigurasi yang meningkatkan performa model tanpa memerlukan biaya komputasi yang tinggi.

II.3 Adagrad

Adagrad merupakan salah satu *adaptive optimizer* yang dirancang untuk menyesuaikan laju pembelajaran (*learning rate*) berdasarkan frekuensi pembaruan parameter [7]. Berbeda dengan *stochastic gradient descent* konvensional yang menggunakan *learning rate* tetap, *Adagrad* menghitung pembobotan *gradien* secara adaptif sehingga parameter yang sering mengalami perubahan akan memiliki *learning rate* lebih kecil, sedangkan parameter yang jarang diperbarui akan mendapatkan *learning rate* lebih besar [8]. Pendekatan ini menjadikan *Adagrad* sangat efektif untuk *dataset* yang memiliki distribusi fitur tidak merata atau mengandung pola kompleks, seperti motif Kawung yang terdiri atas struktur geometri repetitif dan variasi tekstur halus. Mekanisme pembaruan *Adagrad* dilakukan dengan mengakumulasi nilai gradien kuadrat dari setiap parameter. Proses ini dituangkan dalam persamaan:

$$G_t = G_{t-1} + (\nabla_w L(w_t))^2 \quad (2)$$

di mana G_t merupakan akumulasi *gradien* kuadrat hingga iterasi ke- t , dan $\nabla_w L(w_t)$ adalah *gradien* fungsi kerugian pada parameter w_t . Akumulasi ini digunakan untuk menyesuaikan kecepatan pembaruan parameter pada langkah berikutnya. Setelah gradien terakumulasi, pembaruan bobot parameter dilakukan menggunakan persamaan :

$$w_t = w_{t-1} + \frac{\alpha}{\sqrt{G_t - \epsilon}} \nabla_w L(w_{t-1}) \quad (3)$$

dengan α sebagai initial *learning rate* dan ϵ sebagai nilai kecil untuk mencegah pembagian dengan nol. Persamaan ini menunjukkan bahwa semakin besar nilai akumulasi gradien G_t , semakin kecil langkah pembaruan parameter sehingga proses pelatihan menjadi lebih stabil. Keunggulan utama *Adagrad* adalah kemampuannya melakukan adaptasi otomatis terhadap berbagai fitur yang muncul pada citra batik. Dalam konteks klasifikasi motif Kawung, *Adagrad* membantu model mengenali variasi pola elips, ritme motif, serta perubahan intensitas visual secara konsisten. Dengan stabilitas pembaruan parameter yang lebih baik, *Adagrad* menjadi *optimizer* yang relevan dan efektif ketika digunakan bersama arsitektur MobileNetV2 untuk tugas klasifikasi motif batik.

II.4 Evaluasi Model

Evaluasi model merupakan tahap penting dalam mengukur efektivitas sistem klasifikasi citra berbasis *deep learning* [9]. Proses ini dilakukan untuk menilai seberapa baik model mampu mengenali pola visual motif Kawung setelah melalui proses pelatihan. Pada penelitian klasifikasi citra, beberapa metrik yang umum digunakan adalah *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Metrik tersebut tidak hanya memberikan gambaran kinerja model secara keseluruhan, tetapi juga menilai kualitas prediksi pada setiap kelas secara terpisah.


Accuracy mengukur proporsi prediksi yang benar terhadap seluruh prediksi yang dihasilkan, sedangkan *precision* menunjukkan tingkat ketepatan model dalam memberikan prediksi positif. *Recall* mengukur kemampuan model dalam menemukan seluruh sampel dari kelas tertentu, dan *F1-score* merupakan rata-rata harmonik antara *precision* dan *recall* yang berguna ketika distribusi kelas tidak seimbang. Visualisasi menggunakan *confusion matrix* memberikan informasi lebih rinci mengenai jumlah prediksi benar maupun salah pada setiap kelas, sehingga memudahkan identifikasi pola kesalahan klasifikasi.

Dalam konteks klasifikasi motif Kawung, evaluasi berbasis metrik-metrik tersebut sangat penting karena motif ini memiliki pola repetitif dan elemen geometris yang dapat menyebabkan ambiguitas fitur. Oleh karena itu, penggunaan evaluasi berlapis dengan kombinasi skor numerik dan visualisasi matriks kesalahan membantu memastikan bahwa model tidak hanya menghasilkan nilai akurasi tinggi, tetapi juga mendistribusikan prediksi secara konsisten pada setiap kelas. Dengan demikian, tahap evaluasi menjadi komponen utama yang menentukan keberhasilan penggunaan MobileNetV2, Random Search, dan optimizer Adagrad dalam menghasilkan model klasifikasi yang andal.

III. HASIL DAN ANALISIS

III.1 Distribusi Dataset


Distribusi dataset ditampilkan pada Gambar 2. Dataset terdiri dari dua kelas yaitu Kawung dan Lainnya, masing-masing memiliki jumlah data latih dan validasi yang relatif seimbang, sehingga membantu model belajar pola visual tanpa bias kelas yang berlebihan.



Gambar 2. Distribusi Dataset

III.2 Riwayat Pelatihan Model

Riwayat pelatihan model ditunjukkan pada Gambar 3. Kurva *accuracy* menunjukkan peningkatan stabil pada data latih dan validasi. Titik dimulainya tahap *fine-tuning* pada epoch ke-10 juga terlihat memberikan peningkatan akurasi hingga mencapai nilai mendekati 1.00 pada data latih dan sekitar 0.96 pada data validasi. Sementara itu, kurva *loss* pada Gambar 3 menurun secara konsisten, menunjukkan bahwa model mengalami proses pembelajaran yang stabil dan tidak mengalami gejala *overfitting* yang signifikan.



Gambar 3. Performa Pelatihan

III.3 Classification Report

Evaluasi model menggunakan metrik *precision*, *recall*, *F1-score*, dan *accuracy* ditampilkan pada Tabel 3.1. Model mencapai *accuracy* sebesar 0.96, menunjukkan performa klasifikasi yang sangat baik. Kelas Kawung memiliki *precision* 0.95 dan *recall* 0.98, menandakan model mampu mengenali motif Kawung dengan sangat akurat. Sementara itu, kelas Lainnya memiliki *precision* 0.98 dan *recall* 0.94, menunjukkan bahwa model juga mampu membedakan kelas non-Kawung dengan baik.


Tabel 1. *Confusion Matrix*

Class	Precision	Recall	F-1 Score
Kawung	0.9508	0.9831	0.9667
Lainny	0.9804	0.9434	0.9615
Average	0.9656	0.9632	0.9641

III.4 Confusion Matrix

Confusion matrix pada Gambar 3.4 memberikan gambaran lebih detail mengenai distribusi prediksi model. Dari 118 citra Kawung, model berhasil mengklasifikasikan 116 citra dengan benar (98.3%) dan hanya salah memprediksi 2 citra (1.7%). Pada kelas Lainnya, sebanyak 100 citra (94.3%) diprediksi benar, sementara 6 citra (5.7%) salah diklasifikasikan sebagai Kawung. Pola ini menunjukkan bahwa model memiliki

sensitivitas tinggi terhadap motif Kawung dan tetap mampu mengenali kelas lain dengan tingkat kesalahan yang sangat rendah.



Gambar 4. Confusion Matrix

III.5 Analisis

Secara keseluruhan, hasil evaluasi menunjukkan bahwa model *MobileNetV2* dengan optimasi *Random Search* dan Adagrad mampu mengklasifikasikan motif Kawung dengan sangat baik. Kurva pelatihan yang stabil, nilai metrik yang tinggi, serta distribusi kesalahan yang kecil pada *confusion matrix* menandakan bahwa model tidak hanya akurat tetapi juga konsisten dalam membedakan pola visual Kawung dan *non-Kawung*. Kinerja ini memperlihatkan bahwa pendekatan optimasi yang digunakan efektif untuk menangani karakteristik geometris motif Kawung yang repetitif dan kompleks.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa optimasi menggunakan *Random Search* dan optimizer Adagrad pada arsitektur *MobileNetV2* mampu menghasilkan model klasifikasi motif Kawung yang akurat dan stabil. Berdasarkan hasil evaluasi, model mencapai *accuracy* sebesar 0.96, dengan performa yang konsisten pada kedua kelas, ditunjukkan melalui nilai *precision*, *recall*, dan *F1-score* yang tinggi. Visualisasi *confusion matrix* juga memperlihatkan distribusi prediksi yang sangat baik, dengan tingkat kesalahan yang rendah pada kedua kelas. Hasil ini membuktikan bahwa pendekatan optimasi yang digunakan efektif dalam mengatasi pola geometris repetitif pada motif Kawung, sehingga dapat menjadi landasan bagi pengembangan sistem klasifikasi batik yang lebih luas berbasis *deep learning* dan arsitektur *lightweight*.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Bapak Arman dan Ibu Kartika selaku dosen pembimbing yang telah memberikan arahan, masukan, serta bimbingan selama proses penelitian dan penyusunan artikel ini. Ucapan terima kasih juga disampaikan kepada tim penerbit *DISCOVER* yang telah memberikan kesempatan dan fasilitas

publikasi sehingga penelitian ini dapat tersampaikan dengan baik. Dukungan dan kontribusi seluruh pihak menjadi bagian penting dalam terselesaikannya penelitian ini.

REFERENSI

- [1] A. Wahida, E. S. Handayani, and S. Supriyadi, "The Philosophical Values of Kawung Batik Motif in Contemporary Batik Painting," *Mudra J. Seni Budaya*, vol. 35, no. 1, pp. 76–82, 2020, doi: 10.31091/mudra.v35i1.1001.
- [2] A. Boulahya, "Tomato Fruit Diseases Classification using MobileNetV2," *Eng. Technol. J.*, vol. 10, no. 07, pp. 5607–5616, 2025, doi: 10.47191/etj/v10i07.05.
- [3] C. Y. Kim, K. S. Um, and S. W. Heo, "A novel MobileNet with selective depth multiplier to compromise complexity and accuracy," *ETRI J.*, vol. 45, no. 4, pp. 666–677, 2023, doi: 10.4218/etrij.2022-0103.
- [4] J. Zhan, "MobileNet Compression and Edge Computing Strategy for Low- Latency Monitoring," vol. 4, no. 4, 2024.
- [5] L. Li and A. Talwalkar, "Random Search and Reproducibility for Neural Architecture Search," *Proc. Mach. Learn. Res.*, vol. 115, pp. 367–377, 2019.
- [6] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 4510–4520, 2018, doi: 10.1109/CVPR.2018.00474.
- [7] D. Choi, C. J. Shallue, Z. Nado, J. Lee, C. J. Maddison, and G. E. Dahl, "On Empirical Comparisons of Optimizers for Deep Learning," no. 1, 2020, [Online]. Available: <http://arxiv.org/abs/1910.05446>
- [8] G. H. de Rosa, D. Rodrigues, and J. P. Papa, "Opytimizer: A Nature-Inspired Python Optimizer," pp. 1–17, 2019, [Online]. Available: <http://arxiv.org/abs/1912.13002>
- [9] A. Jordan *et al.*, "Improving Batik Classification using CNN Advanced Improving Batik Pattern Pattern Classification on using CNN with with Advanced Augmentation and Oversampling Imbalanced Dataset Improving Batik Pattern Classification using CNN with Advanced Augmentation a," *Procedia Comput. Sci.*, vol. 227, pp. 508–517, 2023, doi: 10.1016/j.procs.2023.10.552.