

Klasifikasi Motif Batik Tradisional Mataraman Menggunakan CNN

Mochammad Rifky Andrianto¹, Ferdi Firdaus Ega Pratama², Reynanda Sigit Purnama³, Eva Yulia Puspaningrum^{4*}

^{1,2,3,4}(Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur)

¹122081010013@student.upnjatim.ac.id

²22081010247@student.upnjatim.ac.id

³22081010275@student.upnjatim.ac.id

⁴evapuspaningrum.if@upnjatim.ac.id

⁴(Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur)

*Corresponding author email: evapuspaningrum.if@upnjatim.ac.id

Abstrak— Batik merupakan salah satu warisan budaya Indonesia yang memiliki makna seni dan filosofi yang mendalam, terutama pada motif-motif tradisional dari daerah Mataraman. Keunikan motif batik yang sangat beragam, baik dari segi pola maupun warna, menjadikannya sebuah tantangan dalam identifikasi otomatis, terutama menggunakan teknologi pengolahan citra digital. Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi model *Convolutional Neural Network* (CNN) untuk mengklasifikasikan empat jenis motif batik Mataraman, yaitu Keraton, Sekar, Sogan, dan Tambal, yang menggunakan citra berwarna *RGB*. *Dataset* yang digunakan dalam penelitian ini terdiri dari 188 gambar asli yang kemudian diaugmentasi menjadi 752 gambar, yang kemudian dibagi secara proporsional menjadi set pelatihan, validasi, dan pengujian. Model CNN yang dikembangkan menggunakan arsitektur *sequential* yang terdiri dari beberapa lapisan konvolusional, *max pooling*, *dropout*, dan lapisan output *softmax* untuk klasifikasi multikelas. Model ini berhasil mencapai akurasi validasi sebesar 72 persen, dengan kinerja terbaik ditemukan pada motif Sekar, sedangkan akurasi terendah ditemukan pada motif Sogan. Hasil penelitian ini menunjukkan bahwa fitur warna memiliki peran yang sangat penting dalam membedakan motif-motif batik yang memiliki kemiripan bentuk, namun memiliki perbedaan pada aspek warna. Penelitian ini juga menyoroti pentingnya teknik augmentasi data yang tepat untuk meningkatkan kinerja model dalam klasifikasi motif batik. Potensi penggunaan metode CNN untuk klasifikasi batik ini dapat diterapkan lebih lanjut untuk pengembangan sistem pengenalan motif batik secara otomatis.

Kata Kunci: CNN, Batik Mataraman, Klasifikasi Citra, RGB, Augmentasi.

I. PENDAHULUAN

Batik merupakan salah satu warisan budaya Indonesia yang telah diakui oleh UNESCO sebagai warisan budaya tak benda dunia [1]. Setiap daerah di Indonesia memiliki corak dan motif batik yang khas, mencerminkan nilai-nilai budaya, sejarah, serta filosofi masyarakat setempat. Salah satu daerah dengan kekayaan motif batik yang tinggi adalah wilayah Mataraman yang mencakup Yogyakarta, Solo, dan sekitarnya. Di wilayah ini, beberapa motif batik yang terkenal antara lain adalah batik Keraton, batik Sekar, batik Sogan, dan batik Tambal [2].

Dengan banyaknya ragam motif batik, proses identifikasi secara manual menjadi kurang efisien dan rawan kesalahan. Oleh karena itu, diperlukan pendekatan otomatis berbasis teknologi, khususnya melalui pemanfaatan pengolahan citra digital dan kecerdasan buatan. Salah satu metode yang terbukti efektif dalam klasifikasi citra adalah *Convolutional Neural Network* (CNN), yang dikenal mampu mengenali pola visual kompleks secara otomatis [3].

Dalam penerapannya pada klasifikasi motif batik, representasi citra yang digunakan sebagai input untuk model CNN dapat mempengaruhi kinerja model. Beberapa studi sebelumnya menunjukkan bahwa hasil klasifikasi dapat bervariasi tergantung pada informasi visual yang disediakan, seperti tekstur dan warna [4]. Misalnya, penelitian oleh Mawan (2020) [5] menunjukkan bahwa pada kasus tertentu, model dengan citra grayscale justru mampu menghasilkan akurasi lebih tinggi dibandingkan citra berwarna. Namun demikian, motif batik umumnya memiliki corak dan pewarnaan yang khas, sehingga representasi warna tetap menjadi aspek penting dalam proses pengenalan pola.

Penelitian ini dilakukan untuk mengembangkan model klasifikasi motif batik tradisional Mataraman menggunakan CNN. Dalam prosesnya, digunakan beberapa jenis representasi citra untuk melatih model, namun pembahasan difokuskan pada hasil terbaik yang diperoleh dari model dengan input citra berwarna (*RGB*). Melalui pendekatan ini, diharapkan penelitian dapat memberikan kontribusi terhadap pengembangan sistem identifikasi batik otomatis yang efisien dan akurat.

Langkah-langkah dalam penelitian ini secara umum meliputi enam tahapan utama yang saling terintegrasi. Pertama, pengumpulan data dilakukan dengan mengambil *dataset* citra batik dari sumber daring terpercaya, yaitu Kaggle. Tahap ini bertujuan untuk memperoleh data yang representatif dan relevan terhadap motif batik tradisional yang diteliti. Kualitas dan keberagaman *dataset* sangat penting karena akan memengaruhi akurasi serta kemampuan generalisasi model klasifikasi secara keseluruhan [6].

Kedua, dilakukan pra-pemrosesan data, yang mencakup perubahan ukuran citra menjadi 150x150 piksel untuk menyeragamkan dimensi input pada CNN, serta normalisasi nilai piksel ke rentang [0,1] dengan membaginya dengan 255.

Proses ini bertujuan mempercepat konvergensi pelatihan dan menjaga kestabilan jaringan [7].

Ketiga, dilakukan augmentasi data, yaitu penambahan variasi data citra secara artifisial melalui rotasi, flipping, zooming, dan translasi. Teknik ini telah terbukti sangat efektif dalam memperluas ruang data pelatihan dan mengurangi risiko overfitting, terutama ketika *dataset* yang digunakan relatif terbatas [8]. Dalam studi lain, augmentasi juga mampu meningkatkan akurasi hingga 10–15% pada *dataset* kecil [9]. Keempat, *dataset* dibagi menjadi tiga bagian utama, yakni 70% untuk data latih, 20% untuk validasi, dan 10% untuk data uji. Pembagian dilakukan secara stratified agar distribusi antar kelas tetap seimbang dan model dapat belajar secara adil terhadap semua kelas. Praktik ini juga menghindari bias data dan menjaga validitas pengujian model.

Kelima, dilakukan pembangunan model CNN menggunakan arsitektur *sequential* yang terdiri dari beberapa lapisan konvolusi, *max pooling*, *flatten*, dan *dense*. CNN dipilih karena kemampuannya dalam mengekstraksi fitur spasial dari citra, serta efektivitasnya dalam tugas klasifikasi gambar yang melibatkan tekstur dan pola [10]. Penggunaan fungsi aktivasi *ReLU* pada tiap lapisan konvolusi membantu mempercepat proses pembelajaran tanpa memperkenalkan kompleksitas komputasi tambahan [11].

Untuk mencegah overfitting, model juga dilengkapi dengan teknik regularisasi seperti *Dropout* dan *L2 regularization*, yang terbukti mampu memperkuat kemampuan generalisasi model [12]. Selain itu, *optimizer Adam* digunakan karena keunggulannya dalam adaptasi pembelajaran dan stabilitas konvergensi, sedangkan fungsi *loss categorical crossentropy* dipilih karena sesuai dengan kasus klasifikasi multikelas [13]. Keenam, performa model dievaluasi menggunakan metrik klasifikasi seperti akurasi, presisi, *recall*, dan *F1-score*. Evaluasi ini memberikan gambaran menyeluruh terhadap kinerja model, tidak hanya dari segi prediksi benar (akurasi), tetapi juga dari kemampuan membedakan antar kelas dengan baik (presisi dan *recall*), serta keseimbangan antara keduanya (*F1-score*) [14]. Penambahan metrik *Matthews Correlation Coefficient* (MCC) juga direkomendasikan dalam studi klasifikasi multikelas untuk menilai performa secara objektif dalam data tidak seimbang [15].

II. METODOLOGI PENELITIAN

Penelitian ini terdiri dari beberapa tahapan utama yang saling berkaitan, yaitu pengumpulan data, pra-pemrosesan data, augmentasi data, pelatihan model *Convolutional Neural Network* (CNN), dan evaluasi performa model. *Dataset* yang digunakan mencakup empat jenis batik tradisional khas daerah Mataraman, yaitu batik Keraton, Sekar, Sogan, dan Tambal. Keempat jenis batik ini dipilih karena memiliki karakteristik visual yang berbeda, sehingga menantang model dalam proses klasifikasi. *Dataset* diperoleh dari sumber daring yang kredibel dan diorganisasikan ke dalam direktori terpisah, di mana masing-masing direktori mewakili satu kelas atau kategori batik. Berikut adalah tahapan metodologi secara rinci:

A. Pengumpulan Data

Dataset gambar batik yang digunakan dalam penelitian ini diperoleh dari situs Kaggle pada tautan: <https://www.kaggle.com/dionisiusdh/indonesian-batik-motifs>. Dari total 3.880 citra batik yang tersedia, telah dilakukan seleksi dan pengelompokan berdasarkan karakteristik visual dan label pada *dataset*.

Penelitian ini memfokuskan pada empat jenis motif batik tradisional khas daerah Mataraman, yaitu batik Keraton, batik Sekar, batik Sogan, dan batik Tambal. Masing-masing kelas motif terdiri dari 47 citra, sehingga total *dataset* yang digunakan dalam penelitian ini berjumlah 188 citra. *Dataset* ini menjadi fondasi utama dalam proses pelatihan dan evaluasi model CNN dengan representasi citra berwarna (*RGB*) untuk mengklasifikasikan motif batik

B. Pra-Pemrosesan Data

Seluruh citra dalam *dataset* mengalami tahap pra-pemrosesan awal, yaitu perubahan ukuran gambar menjadi 150 x 150 piksel. Ukuran ini dipilih untuk menyeragamkan input yang masuk ke dalam arsitektur CNN serta mengurangi kompleksitas komputasi tanpa kehilangan fitur visual penting dari motif batik. Selain itu, ukuran citra tersebut merupakan pilihan yang seimbang antara mempertahankan pola utama dalam motif dan menjaga efisiensi komputasi selama proses pelatihan.

Untuk meningkatkan volume data dan mendorong kemampuan generalisasi model, dilakukan proses augmentasi terhadap citra dalam *dataset*. Teknik augmentasi yang digunakan meliputi rotasi sudut gambar, *zoom* (pembesaran sebagian area gambar), serta *flipping* (pembalikan horizontal dan vertikal). Proses augmentasi ini diterapkan terlebih dahulu terhadap seluruh data citra sebelum dilakukan pembagian *dataset* menjadi data latih, validasi, dan uji. Dengan demikian, data pelatihan diperbanyak melalui augmentasi, sementara data validasi dan pengujian tetap dapat dijaga proporsinya untuk evaluasi performa model secara objektif.


Dataset kemudian dibagi menjadi tiga bagian utama dengan proporsi umum dalam pelatihan model CNN, yaitu 70% untuk data pelatihan, 20% untuk data validasi, dan 10% untuk data pengujian. Pembagian dilakukan secara proporsional terhadap masing-masing kelas agar distribusi jumlah data tetap seimbang di setiap subset. Dengan demikian, model diharapkan mampu belajar dan menggeneralisasi pola dari masing-masing kelas secara adil tanpa bias terhadap kelas tertentu.

Dari total 188 citra asli, setelah dilakukan proses augmentasi total *dataset* berjumlah sebanyak 752, di mana sebanyak 526 citra (70%) digunakan sebagai data pelatihan. Data validasi dan pengujian masing-masing terdiri dari 150 citra (20%) dan 76 citra (10%).

Terakhir, seluruh citra dari ketiga subset (*train*, *val*, dan *test*) juga melalui tahap normalisasi piksel dengan cara membagi nilai setiap piksel dengan 255, sehingga nilainya berada dalam rentang 0 hingga 1. Normalisasi ini bertujuan untuk

mempercepat proses konvergensi saat pelatihan model dan membantu kestabilan pembelajaran dalam jaringan CNN.

C. Membangun Model CNN



Gambar 1. Arsitektur CNN

Model CNN pada gambar 1 dibangun menggunakan arsitektur *sequential* dengan dua lapisan konvolusi utama. Lapisan pertama memiliki 32 filter berukuran 3x3 dengan fungsi aktivasi *ReLU* dan menerima input citra berukuran 150 x 150 piksel dengan tiga kanal warna (*RGB*). Lapisan ini diikuti oleh *MaxPooling2D* dengan ukuran 2x2 untuk mengurangi dimensi spasial. Lapisan konvolusi kedua terdiri dari 64 filter berukuran 3x3 dengan aktivasi *ReLU* dan juga diikuti oleh pooling 2x2. Hasil ekstraksi fitur dari kedua lapisan konvolusi kemudian diflatten menjadi vektor satu dimensi dan diteruskan ke lapisan dense dengan 128 neuron dan aktivasi *ReLU*, serta regularisasi L2 sebesar 0.001 untuk mencegah *overfitting*. Lapisan ini diikuti oleh *Dropout* sebesar 0.5 sebelum masuk ke lapisan output yang memiliki 4 neuron dengan fungsi aktivasi *Softmax* untuk klasifikasi multikelas. Model dikompilasi menggunakan *optimizer Adam* dengan *learning rate* 0.001, fungsi *loss categorical crossentropy*, dan matrik evaluasi akurasi. Pelatihan model dilakukan selama maksimal 50 *epoch* dengan *early stopping* berdasarkan nilai *val_loss* dan *patience* sebanyak 5 *epoch* untuk mencegah *overfitting* dan memastikan bobot terbaik dipertahankan.

Untuk memberikan pemahaman yang lebih jelas mengenai arsitektur model CNN ini, berikut adalah tabel yang merinci setiap lapisan yang digunakan:

Tabel I.
Layer Model CNN

Layer (Type)	Output Shape	Jumlah Parameter
Conv2d (Conv2D)	(None, 148, 148, 32)	896
max_pooling2d (MaxPooling2D)	(None, 74, 74, 32)	0
Conv2d_1 (Conv2D)	(None, 72, 72, 64)	18.496
max_pooling2d_1 (MaxPooling2D)	(None, 36, 36, 64)	0
flatten (Flatten)	(None, 82944)	0
dense (Dense)	(None, 128)	10.616.960
dropout (Dropout)	(None, 128)	0
Dense_1 (Dense)	(None, 4)	516
Total Parameter		10.636.868

D. Pengujian Model CNN

Setelah proses pelatihan selesai, performa model dievaluasi menggunakan beberapa metrik evaluasi standar, antara lain akurasi, presisi, *recall*, dan *F1-score*, untuk mendapatkan gambaran menyeluruh terhadap kemampuan klasifikasi model. Bagian ini memuat rancangan penelitian meliputi desain penelitian, populasi/sampel penelitian, teknik dan instrumen pengumpulan data, alat analisis data, dan model penelitian yang digunakan. Metode yang sudah umum tidak perlu dituliskan secara rinci, tetapi cukup merujuk ke referensi acuan (misalnya: rumus uji-F, uji-t, dll). Pengujian validitas dan reliabilitas instrumen penelitian tidak perlu dituliskan secara rinci, tetapi cukup dengan mengungkapkan hasil pengujian dan interpretasinya. Keterangan simbol pada model dituliskan dalam kalimat.

III. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan model *Convolutional Neural Network* (CNN) untuk melakukan klasifikasi motif batik berdasarkan citra berwarna (*RGB*). *Dataset* yang digunakan telah melalui proses pra-pemrosesan, termasuk perubahan ukuran citra menjadi 150 x 150 piksel, serta pembagian data dengan proporsi 70% untuk pelatihan, 20% untuk validasi, dan 10% untuk pengujian.

Hasil pelatihan menunjukkan bahwa model CNN dengan input citra *RGB* menghasilkan akurasi validasi tertinggi sebesar 72%. Capaian ini mengindikasikan bahwa informasi warna dalam citra memberikan kontribusi signifikan dalam proses klasifikasi, terutama dalam membedakan motif batik yang memiliki kemiripan pola bentuk namun berbeda dalam kombinasi warna.

Performa model CNN sangat dipengaruhi oleh konfigurasi arsitektur dan hyperparameter yang digunakan. Dalam penelitian ini, arsitektur CNN serta parameter pelatihan seperti jumlah filter konvolusi, ukuran kernel, jumlah lapisan, nilai *dropout*, batch size, dan learning rate masih digunakan dalam konfigurasi awal guna mengevaluasi performa dasar model.

Meskipun demikian, eksplorasi terhadap variasi hyperparameter belum dilakukan secara menyeluruh. Oleh karena itu, nilai akurasi yang diperoleh belum dapat dianggap sebagai performa optimal dari model CNN. Terdapat peluang peningkatan akurasi melalui eksperimen lanjutan dengan kombinasi parameter yang berbeda, seperti variasi jumlah filter (misalnya 32, 64, atau 128), ukuran kernel (3x3 atau 5x5), serta penambahan atau pengurangan jumlah lapisan konvolusi. Selain itu, pengaturan nilai *dropout* yang lebih adaptif dan tuning learning rate secara sistematis melalui pendekatan seperti grid search atau random search dapat membantu dalam menemukan konfigurasi terbaik.


Pendekatan lain yang berpotensi meningkatkan performa model adalah dengan memanfaatkan *transfer learning* menggunakan arsitektur CNN pra-latih seperti VGG16, ResNet, atau MobileNet yang telah terbukti efektif pada berbagai tugas klasifikasi citra. Model-model ini dapat

digunakan sebagai *feature extractor* atau *di-fine-tune* sesuai kebutuhan, sehingga diharapkan dapat meningkatkan akurasi dalam klasifikasi motif batik secara signifikan.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa informasi warna memiliki peran penting dalam meningkatkan akurasi klasifikasi motif batik. Selain itu, penelitian ini menekankan pentingnya eksplorasi lanjutan terhadap konfigurasi arsitektur CNN dan hyperparameter untuk memperoleh performa model yang lebih optimal.

A. Hasil Pelatihan CNN

Model CNN dilatih menggunakan *dataset* citra berwarna (RGB) berukuran 150×150 piksel. *Dataset* dibagi dengan proporsi 70% data pelatihan, 20% validasi, dan 10% pengujian. Selama proses pelatihan selama 14 *epoch*, model menunjukkan tren pembelajaran yang cukup stabil dan adaptif.



Gambar 2. Grafik Hasil Pelatihan

Berdasarkan gambar 2, grafik *loss*, nilai *training loss* mengalami penurunan signifikan dari sekitar 2.2 di awal pelatihan menjadi mendekati 0.4 pada akhir *epoch* ke-14. Hal ini menunjukkan bahwa model mampu menyesuaikan bobot dengan baik terhadap data pelatihan. Sementara itu, *validation loss* juga mengalami penurunan dari sekitar 1.3 menjadi sekitar 0.75, meskipun terlihat fluktuasi pada beberapa titik, khususnya di sekitar *epoch* ke-11. Fluktuasi ini mengindikasikan adanya kompleksitas pada data validasi, kemungkinan disebabkan oleh kemiripan pola antar motif batik.

Pada grafik akurasi, *train accuracy* meningkat drastis dari 0.3 menjadi hampir 0.98, menandakan bahwa model sangat baik dalam mempelajari data pelatihan. *Validation accuracy* juga meningkat dari sekitar 0.3 menjadi 0.72 pada *epoch* ke-9, lalu sedikit menurun dan stabil di kisaran 0.68–0.70 hingga akhir pelatihan. Pola ini menunjukkan kemampuan generalisasi yang cukup baik, dengan indikasi *overfitting* ringan yang masih dalam batas wajar.

Sebagai hasil akhir pelatihan, model mencapai akurasi validasi tertinggi sebesar 72%, dengan hasil evaluasi pada data uji seperti ditunjukkan pada Tabel II.

Tabel II
Hasil Evaluasi Model CNN

	Precision	Recall	F1-Score	Support
batik keraton DIR	0.71	0.79	0.75	19
batik sekar DIR	0.93	0.74	0.82	19
batik sogan DIR	0.71	0.53	0.61	19
batik tambal DIR	0.62	0.84	0.71	19

accuracy			0.72	76
macro avg	0.74	0.72	0.72	76
Weighted avg	0.74	0.72	0.72	76

Penjelasan Matriks Evaluasi:

- *Precision* mengukur ketepatan model dalam memprediksi suatu kelas. Sebagai contoh, nilai *precision* sebesar 0.93 pada kelas batik_sekar menunjukkan bahwa 93% dari seluruh prediksi yang diklasifikasikan sebagai batik sekar adalah benar.
- *Recall* menunjukkan kemampuan model dalam menemukan semua data aktual dari suatu kelas. Nilai *recall* 0.84 pada batik_tambal berarti 84% dari seluruh batik tambal yang ada berhasil dikenali oleh model.
- *F1-Score* merupakan rata-rata harmonis dari *precision* dan *recall*, memberikan gambaran menyeluruh tentang keseimbangan performa model.
- *Support* menunjukkan jumlah sampel aktual dari tiap kelas dalam data uji. Masing-masing kelas memiliki 19 sampel, dengan total 76 sampel uji.

Berdasarkan evaluasi, performa model bervariasi di tiap kelas. Model menunjukkan performa sangat baik dalam mengenali batik sekar, namun kurang optimal pada batik sogan, yang kemungkinan disebabkan oleh pola visual yang kurang khas atau mirip dengan kelas lainnya. Hal ini kembali menunjukkan bahwa aspek warna dan bentuk sangat berperan penting dalam proses klasifikasi motif batik.

IV. KESIMPULAN DAN SARAN

Penelitian ini membuktikan bahwa metode *Convolutional Neural Network* (CNN) mampu mengenali pola motif batik tradisional Mataraman dengan baik ketika menggunakan citra berwarna (RGB). Model CNN yang dilatih menggunakan citra RGB berhasil mencapai akurasi uji sebesar 72%, menunjukkan bahwa informasi warna memiliki peranan penting dalam membedakan karakteristik motif batik yang kompleks. Berdasarkan temuan ini, penggunaan citra berwarna lebih direkomendasikan dalam klasifikasi motif batik.

Untuk pengembangan penelitian selanjutnya, disarankan agar dilakukan penerapan teknik augmentasi data yang lebih variatif untuk memperkaya variasi pola serta mencegah model mengalami *overfitting*. Kontrol distribusi kelas juga penting untuk menghindari bias pada model. Eksplorasi lebih lanjut terhadap arsitektur CNN seperti penambahan batch normalization, *dropout*, dan variasi jumlah serta ukuran filter perlu dilakukan untuk meningkatkan performa model. Pendekatan *transfer learning* dengan menggunakan model pra-latih seperti VGG16, ResNet, atau MobileNet juga dapat menjadi alternatif untuk meningkatkan akurasi klasifikasi. Selain itu, penggunaan ukuran gambar yang lebih besar, misalnya 224×224 piksel, diharapkan dapat mempertahankan detail pola batik secara lebih optimal. Penambahan jumlah data pelatihan serta penerapan teknik validasi silang (*cross-validation*) juga dianjurkan guna meningkatkan kemampuan generalisasi model. Dengan menerapkan strategi-strategi

tersebut, diharapkan kinerja model dalam mengklasifikasikan motif batik dapat lebih akurat dan efisien.

V. REFERENSI

- [1] T. A. Bowo, H. Syaputra, and M. Akbar, "Penerapan Algoritma Convolutional Neural Network Untuk Klasifikasi Motif Citra Batik Solo," *J. Softw. Eng. Ampera*, vol. 1, no. 2, pp. 82–96, 2020, doi: 10.51519/journalsea.v1i2.47.
- [2] K. Azmi, S. Defit, and S. Sumijan, "Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," *J. Unitek*, vol. 16, no. 1, pp. 28–40, 2023, doi: 10.52072/unitek.v16i1.504.
- [3] M. A. F. Muthrofin, D. Erwanto, and I. Yanuartanti, "Convolutional Neural Network untuk Klasifikasi Batik Tenun Ikat Bandar Berdasarkan Fitur Warna dan Tekstur," *J. Electr. Eng. Comput.*, vol. 6, no. 1, pp. 120–128, 2024, doi: 10.33650/jeeecom.v6i1.8060.
- [4] Angginy Akhirunnisa Siregar, Citra Citra, Dechy Deswita Indriani.S, and Gifari Dhaffa Prawira Sianturi, "Klasifikasi Batik Parang Menggunakan Convolutional Neural Network (CNN)," *Pop. J. Penelit. Mhs.*, vol. 3, no. 1, pp. 62–69, 2023, doi: 10.58192/populer.v3i1.1666.
- [5] R. Mawan, "Klasifikasi motif batik menggunakan Convolutional Neural Network," *Jnanaloka*, pp. 45–50, 2020, doi: 10.36802/jnanaloka.2020.v1-no1-45-50.
- [6] L. Alzubaidi *et al.*, *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021. doi: 10.1186/s40537-021-00444-8.
- [7] N. L. W. Keijsers, "Neural Networks," *Encycl. Mov. Disord. Three-Volume Set*, pp. V2-257-V2-259, 2010, doi: 10.1016/B978-0-12-374105-9.00493-7.
- [8] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [9] L. Perez and J. Wang, "The Effectiveness of Data Augmentation in Image Classification using Deep Learning," 2017, [Online]. Available: <http://arxiv.org/abs/1712.04621>
- [10] A. Patil and M. Rane, "Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition," *Smart Innov. Syst. Technol.*, vol. 195, pp. 21–30, 2021, doi: 10.1007/978-981-15-7078-0_3.
- [11] H. Li, J. Wang, M. Tang, and X. Li, "Polarization-dependent effects of an Airy beam due to the spin-orbit coupling," *J. Opt. Soc. Am. A Opt. Image Sci. Vis.*, vol. 34, no. 7, pp. 1114–1118, 2017, doi: 10.1002/ecs2.1832.
- [12] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," *J. Mach. Learn. Res.*, vol. 15, pp. 1929–1958, 2014.
- [13] D. P. Kingma and J. L. Ba, "Adam: A method for stochastic optimization," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–15, 2015.
- [14] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Inf. Process. Manag.*, vol. 45, no. 4, pp. 427–437, 2009, doi: 10.1016/j.ipm.2009.03.002.
- [15] D. Chicco and G. Jurman, "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation," *BMC Genomics*, vol. 21, no. 1, pp. 1–13, 2020, doi: 10.1186/s12864-019-6413-7.