

Classification of Javanese Script Characters Using ResNet-50 Architecture Based on Transfer Learning

Taofik Krisdiyanto^{1)*}, Agustin Setiyorini²⁾, Kadang Katon³⁾

¹⁾Program Studi Magister Teknologi Informasi, Fakultas Teknik, Universitas Gadjah Mada

¹⁾²⁾³⁾Program Studi Sarjana Informatika, Fakultas Teknik, Universitas Janabadra

^{*)}Correspondence author: taofik@janabadra.ac.id, Yogyakarta, Indonesia

DOI: <https://doi.org/10.37012/jtik.v12i2.3888>

Abstract

Javanese script is one of Indonesia's cultural heritages that has complex visual characteristics and high similarity among characters, making automatic character recognition a challenging task. Recent advances in deep learning, particularly Convolutional Neural Networks (CNNs), have shown promising performance in image classification problems. This study aims to develop and evaluate a Javanese character classification model using the ResNet-50 architecture based on transfer learning. The dataset consists of digital images of basic Javanese characters that were preprocessed through image resizing, normalization, and data augmentation. ResNet-50 was employed as the main feature extractor, with modifications applied to the final classification layer according to the number of character classes. Model performance was evaluated using accuracy, precision, recall, and F1-score metrics, supported by confusion matrix analysis. The experimental results indicate that the ResNet-50 model achieves stable and reliable performance in classifying Javanese characters. The use of transfer learning and data augmentation contributes to improved generalization capability. These findings demonstrate that deep CNN architectures such as ResNet-50 are effective for Javanese character recognition and have potential applications in digital learning and cultural preservation systems.

Keywords: Javanese script, Deep learning, Image classification, ResNet50, Transfer learning.

Abstrak

Aksara Jawa merupakan salah satu warisan budaya Indonesia yang memiliki karakteristik visual kompleks serta kemiripan tinggi antar karakter, sehingga pengenalan karakter secara otomatis menjadi tugas yang menantang. Kemajuan terkini dalam deep learning, khususnya Convolutional Neural Networks (CNN), telah menunjukkan kinerja yang menjanjikan dalam masalah klasifikasi citra. Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model klasifikasi aksara Jawa menggunakan arsitektur ResNet-50 berbasis transfer learning. Dataset yang digunakan terdiri dari citra digital aksara Jawa dasar yang telah melalui tahap pra-pemrosesan berupa penyesuaian ukuran citra resizing, normalisasi, dan augmentasi data. ResNet-50 digunakan sebagai ekstraktor fitur utama, dengan modifikasi pada lapisan klasifikasi akhir yang disesuaikan dengan jumlah kelas aksara. Kinerja model dievaluasi menggunakan metrik accuracy, precision, recall, dan F1-score, serta didukung oleh analisis confusion matrix. Hasil eksperimen menunjukkan bahwa model ResNet-50 mencapai kinerja yang stabil dan andal dalam mengklasifikasikan aksara Jawa. Penggunaan transfer learning dan augmentasi data berkontribusi pada peningkatan kemampuan generalisasi model. Temuan ini menunjukkan bahwa arsitektur CNN yang dalam, seperti ResNet-50, efektif untuk pengenalan aksara Jawa serta memiliki potensi penerapan dalam sistem pembelajaran digital dan pelestarian budaya.

Kata Kunci: Aksara jawa, Deep learning, Klasifikasi citra, Resnet50, Transfer learning.

PENDAHULUAN

Aksara Jawa merupakan salah satu warisan budaya Indonesia yang memiliki nilai historis dan linguistik tinggi, namun penggunaannya dalam kehidupan sehari-hari semakin berkurang seiring dengan dominasi sistem tulisan modern (Mahastama & Krisnawati, 2020). Kondisi ini berdampak pada menurunnya kemampuan generasi muda dalam mengenali dan memahami karakter aksara Jawa (Adli Kesaulya et al., 2022; Maulana, 2024). Pemanfaatan teknologi pengolahan citra dan kecerdasan buatan menjadi salah satu pendekatan yang berpotensi mendukung upaya pelestarian dan pembelajaran aksara Jawa melalui sistem pengenalan karakter secara otomatis (Muhdalifah, 2022).

Pengenalan karakter aksara Jawa memiliki tantangan tersendiri karena kompleksitas bentuk visual serta kemiripan antar karakter (Chen et al., 2015). Beberapa penelitian telah mencoba menerapkan CNN untuk mengenali karakter aksara Jawa (Susanto et al., 2024). Salah satu studi menggunakan arsitektur ResNet-18 dan menunjukkan hasil yang sangat menjanjikan dengan akurasi validasi mencapai 98,01% serta skor precision, recall, dan F1-Score yang sempurna, menandakan potensi besar penggunaan CNN untuk pengenalan aksara Hanacaraka (Sudewo et al., 2024).

Perkembangan arsitektur CNN modern, seperti Residual Network (ResNet), menawarkan solusi melalui mekanisme residual learning yang memungkinkan pelatihan jaringan dalam lebih stabil (Sudewo et al., 2024). Studi komparatif lainnya menunjukkan bahwa arsitektur seperti VGG19 dan DenseNet memberikan akurasi tinggi, namun ResNet, meskipun sedikit tertinggal dari segi akurasi, menawarkan keunggulan dalam efisiensi komputasi dan stabilitas model dalam berbagai kondisi data (Susanto et al., 2024).

Pemanfaatan arsitektur ResNet-50 dengan pendekatan transfer learning telah terbukti efektif pada berbagai tugas klasifikasi citra, terutama ketika jumlah data pelatihan terbatas (Sudewo et al., 2024). Meskipun demikian, kajian yang secara khusus mengimplementasikan dan mengevaluasi ResNet-50 untuk klasifikasi karakter aksara Jawa masih relatif terbatas, sehingga diperlukan penelitian lebih lanjut pada domain ini.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimen berbasis deep learning untuk mengklasifikasikan karakter aksara Jawa dari citra digital (Priyambodo et al., 2024). Tahapan metodologi penelitian meliputi pengumpulan dataset, pra-pemrosesan data, perancangan dan pelatihan model, serta evaluasi kinerja model (Rahmawati et al., 2024).



Gambar 1. Tahapan Penelitian

Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini merupakan dataset citra karakter aksara Jawa (Hanacaraka) yang diperoleh dari sumber terbuka Kaggle (Nugroho, 2024). Dataset terdiri dari citra karakter aksara Jawa dasar dengan beberapa kelas yang merepresentasikan masing-masing karakter (Rasyidi et al., 2021). Seluruh dataset dibagi menjadi data latih dan data uji untuk keperluan pelatihan dan evaluasi model. Pembagian data dilakukan secara terstruktur guna memastikan representasi setiap kelas tetap seimbang (Harjoseputro, 2020).

Pra Pemrosesan Data

Sebelum digunakan dalam proses pelatihan, seluruh citra dataset melalui tahapan pra-pemrosesan. Tahapan ini meliputi penyesuaian ukuran citra agar sesuai dengan input model ResNet-50, normalisasi nilai piksel, serta konversi format citra ke dalam bentuk yang kompatibel dengan arsitektur CNN (Al Haromainy et al., 2022). Selain itu, augmentasi data diterapkan pada data latih untuk meningkatkan variasi data dan mengurangi risiko overfitting (Wawan et al., 2024). Teknik augmentasi yang digunakan meliputi rotasi, pergeseran, dan transformasi citra sederhana lainnya (Hamdi et al., 2021).

Arsitektur Model

Model yang digunakan dalam penelitian ini adalah arsitektur ResNet-50 yang diimplementasikan menggunakan pendekatan transfer learning (Liu et al., 2021; Saidulu et al., 2022). ResNet-50 dimanfaatkan sebagai ekstraktor fitur utama dengan bobot awal yang diperoleh dari model pra-latih pada dataset berskala besar. Lapisan klasifikasi pada bagian akhir model dimodifikasi dan disesuaikan dengan jumlah kelas karakter aksara Jawa yang digunakan dalam penelitian ini (Saidulu et al., 2022). Pendekatan ini memungkinkan model memanfaatkan fitur visual tingkat tinggi yang telah dipelajari sebelumnya, sehingga proses pelatihan menjadi lebih efisien (Chauhan et al., 2024).

Proses Pelatihan Model

Proses pelatihan model dilakukan menggunakan data latih yang telah melalui tahapan pra-pemrosesan dan augmentasi (Cheekati & Rajeti, 2020). Model dilatih selama sejumlah epoch tertentu dengan menggunakan fungsi loss kategorikal dan algoritma optimasi berbasis gradient descent (Aamir et al., 2019). Selama proses pelatihan, performa model dipantau melalui nilai train loss dan test loss untuk memastikan proses pembelajaran berjalan dengan baik serta menghindari terjadinya overfitting (Jonathan & Wasito, 2023).

Evaluasi Model


Evaluasi kinerja model dilakukan menggunakan data uji yang tidak dilibatkan dalam proses pelatihan. Performa model diukur menggunakan beberapa metrik evaluasi, yaitu accuracy, precision, recall, dan F1-score (He et al., 2016). Selain itu, confusion matrix digunakan untuk menganalisis kesalahan klasifikasi antar kelas karakter aksara Jawa (Erhani et al., 2024). Hasil evaluasi ini digunakan sebagai dasar untuk menilai kemampuan generalisasi model

serta efektivitas arsitektur ResNet-50 dalam melakukan klasifikasi karakter aksara Jawa (Faishal et al., 2023).

HASIL DAN PEMBAHASAN

Hasil Pengumpulan Dataset

Dataset citra karakter dasar aksara Jawa (Hanacaraka) berhasil dikumpulkan dari sumber terbuka [9]. Dataset tersebut terdiri dari beberapa kelas karakter aksara Jawa dengan variasi bentuk visual. Dataset berisi kurang lebih ± 500 tulisan tangan digital dalam format PNG. Setiap huruf pada aksara Jawa Hanacaraka berisi sekitar ± 75 yang memiliki resolusi beragam tetapi dibawah 500x500 pixel. Contoh dataset yang digunakan dapat dilihat pada Gambar 2.



Gambar 2. Contoh citra dataset aksara Jawa

Pra Pemrosesan Data


Dataset kemudian dibagi menjadi dua jenis yaitu data training digunakan untuk melakukan pembelajaran model dan data testing digunakan untuk melakukan uji coba model yang sudah dikembangkan. Untuk memastikan keseragaman dan kualitas data, seluruh citra telah melalui proses pra-pemrosesan seperti pada Tabel 1. yang meliputi penyesuaian ukuran citra, normalisasi nilai pixel, serta augmentasi data.

Tabel 1.

Tahapan Pra-pemrosesan Data

Tahapan pra-pemrosesan	Deskripsi
Resize citra	Penyesuaian ukuran citra agar seragam sesuai input model
Normalisasi	Skala nilai piksel untuk mempercepat konvergensi model
Data augmentation	Rotasi, flipping, dan transformasi ringan untuk menambah variasi data

Tahapan ini bertujuan untuk meningkatkan kualitas dataset dan mengurangi potensi overfitting selama proses pelatihan model. Hasil tahapan pra-pemrosesan dapat dilihat pada Gambar 3. terlihat bahwa beberapa citra terjadi rotasi dan flipping untuk meningkatkan kualitas data.



Gambar 3. Citra dataset setelah tahapan pra-pemrosesan

Hasil Pelatihan Data

Model klasifikasi karakter aksara Jawa dikembangkan menggunakan arsitektur ResNet-50 berbasis transfer learning. Lapisan awal ResNet-50 digunakan sebagai ekstraktor fitur, sedangkan lapisan akhir disesuaikan dengan jumlah kelas karakter aksara Jawa. Proses pelatihan dilakukan sebanyak 50 kali atau epoch menggunakan bahasa pemrograman Python dengan parameter pelatihan yang telah disesuaikan. Model yang dikembangkan juga dilakukan uji coba dengan data testing untuk memastikan model dapat menjadi melakukan klasifikasi aksara jawa dengan hasil seperti pada Gambar 4.



Gambar 4. Hasil klasifikasi oleh model yang telah dikembangkan

Evaluasi Kinerja Klasifikasi


Evaluasi performa model dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score. Evaluasi ini bertujuan untuk mengukur tingkat keberhasilan model dalam mengenali karakter aksara Jawa secara menyeluruh. Hasil evaluasi dapat dilihat pada Tabel 2.

Tabel 2.

Hasil Evaluasi Kinerja Klasifikasi


Metrik Evaluasi	Nilai
<i>Accuracy</i>	93,17%
<i>Precision</i>	91,12%
<i>Recall</i>	89,50%
<i>F1-Score</i>	92,17%

Gambar 5. menunjukkan bahwa dalam proses pelatihan sebanyak 50 kali tercapai akurasi maksimal di proses ke 24 dengan tingkat akurasi sebanyak 96,17%.



Gambar 5. Hasil akurasi selama proses pelatihan


Selain melakukan evaluasi metrik accuracy, precision, recall dan F1-Score juga dilakukan evaluasi train loss dan test loss untuk memantau proses pembelajaran model selama pelatihan serta mengukur kemampuan generalisasi model terhadap data yang tidak digunakan dalam proses training. Gambar 6. Menunjukkan pola penurunan train loss yang diikuti dengan stabilnya test loss menunjukkan bahwa model mampu belajar secara optimal tanpa mengalami overfitting yang signifikan.



Gambar 6. Hasil evaluasi train loss dan test loss

Analisis Confusion Matrix

Confusion matrix digunakan untuk menganalisis kesalahan klasifikasi antar karakter aksara Jawa. Berdasarkan Gambar 7. menunjukkan bahwa sebagian besar karakter berhasil diklasifikasikan dengan benar. Kesalahan klasifikasi umumnya terjadi pada karakter yang memiliki kemiripan bentuk visual, terutama pada bagian lengkungan dan garis tertentu.



Gambar 7. Hasil analisis confusion matrix

Pembahasan

Hasil penelitian ini menunjukkan bahwa penerapan arsitektur ResNet-50 berbasis transfer learning mampu meningkatkan kinerja klasifikasi karakter aksara Jawa dibandingkan pendekatan CNN yang lebih sederhana. Mekanisme residual learning pada ResNet-50 memungkinkan pelatihan jaringan yang lebih dalam secara stabil, sehingga model dapat mengekstraksi fitur visual tingkat tinggi secara lebih efektif. Selain itu, penerapan augmentasi data berperan penting dalam meningkatkan kemampuan generalisasi model terhadap variasi bentuk karakter. Kombinasi antara transfer learning dan augmentasi data terbukti membantu mengurangi risiko overfitting serta meningkatkan stabilitas performa model pada data uji. Dengan demikian, hasil penelitian ini memperkuat temuan-temuan sebelumnya terkait efektivitas CNN dalam pada pengenalan karakter, sekaligus memberikan kontribusi spesifik pada domain pengenalan aksara Jawa.

KESIMPULAN DAN REKOMENDASI

Penelitian ini berhasil mengembangkan model klasifikasi karakter aksara Jawa menggunakan arsitektur ResNet-50 berbasis transfer learning. Hasil evaluasi menunjukkan bahwa model mampu mencapai performa klasifikasi yang baik dan stabil, ditunjukkan oleh nilai metrik evaluasi serta pola train loss dan test loss yang terkontrol. Selama proses pelatihan sebanyak 50 kali tercapai akurasi maksimal di proses ke 24 dengan tingkat akurasi sebanyak 96,17%.

Analisis hasil pengujian menunjukkan bahwa kesalahan klasifikasi masih terjadi pada karakter yang memiliki kemiripan visual, namun secara umum model menunjukkan kemampuan generalisasi yang baik. Dengan demikian, arsitektur ResNet-50 berbasis transfer learning terbukti efektif untuk pengenalan karakter aksara Jawa dan berpotensi dikembangkan lebih lanjut untuk mendukung aplikasi pembelajaran dan pelestarian aksara Jawa berbasis teknologi digital.

REFERENSI

1. Aamir, M., Rahman, Z., Ahmed Abro, W., Tahir, M., & Mustajar Ahmed, S. (2019). An optimized architecture of image classification using convolutional neural network. *International Journal of Image, Graphics and Signal Processing*, 11(10), 30–39. <https://doi.org/10.5815/ijigsp.2019.10.05>
2. Adli Kesaulya, G. N., Fariza, A., & Karlita, T. (2022). Javanese script text image recognition using convolutional neural networks. In *2022 International Electronics Symposium (IES)* (pp. 534–539). <https://doi.org/10.1109/IES55876.2022.9888527>
3. Al Haromainy, M. M., Sihananto, A. N., Prasetya, D. A., Sari, A. P., Alfyando, M., & Purnomo, R. (2022). Classification of Javanese script using convolutional neural network with data augmentation. In *2022 IEEE 8th Information Technology International Seminar (ITIS)* (pp. 288–291). <https://doi.org/10.1109/ITIS57155.2022.10010262>
4. Chauhan, V. K., Singh, S., & Sharma, A. (2024). HCR-Net: A deep learning-based script-independent handwritten character recognition network. *Multimedia Tools and Applications*, 83(32), 78433–78467. <https://doi.org/10.1007/s11042-024-18655-5>
5. Cheekati, B. M., & Rajeti, R. S. (2020). Telugu handwritten character recognition using deep residual learning. In *2020 Fourth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)* (pp. 788–796). <https://doi.org/10.1109/I-SMAC49090.2020.9243348>
6. Chen, L., Wang, S., Fan, W., Sun, J., & Naoi, S. (2015). Beyond human recognition: A CNN-based framework for handwritten character recognition. In *2015 3rd IAPR Asian Conference on Pattern Recognition (ACPR)* (pp. 695–699). <https://doi.org/10.1109/ACPR.2015.7486592>
7. Erbani, J., Portier, P.-É., Egyed-Zsigmond, E., & Nurbakova, D. (2024). Confusion matrices: A unified theory. *IEEE Access*, 12, 181372–181419. <https://doi.org/10.1109/ACCESS.2024.3507199>
8. Faishal, M. H., Sulistiyo, M. D., & Ihsan, A. F. (2023). Javanese script letter detection using Faster R-CNN. *Indonesian Journal of Artificial Intelligence and Data Mining*, 6(2), 243. <https://doi.org/10.24014/ijaidm.v6i2.24641>

9. Hamdi, Y., Boubaker, H., & Alimi, A. M. (2021). Data augmentation using geometric, frequency, and beta modeling approaches for improving multilingual online handwriting recognition. *International Journal on Document Analysis and Recognition*, 24(3), 283–298. <https://doi.org/10.1007/s10032-021-00376-2>
10. Harjoseputro, Y. (2020). A classification Javanese letters model using a convolutional neural network with KERAS framework. *International Journal of Advanced Computer Science and Applications*, 11(10). <https://doi.org/10.14569/IJACSA.2020.0111014>
11. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 770–778). <https://doi.org/10.1109/CVPR.2016.90>
12. Jonathan, A., & Wasito, I. (2023). Perancangan aplikasi pengenalan aksara Jawa digital menggunakan convolutional neural network dan computer vision. *Decode: Jurnal Pendidikan Teknologi Informasi*, 3(2), 364–377. <https://doi.org/10.51454/decode.v3i2.209>
13. Liu, L., Cheng, J., Xie, L., Song, J., Zhou, K., & Liu, J. (2021). A transfer learning method based on ResNet model. In *[Informasi judul buku atau prosiding perlu dilengkapi]* (pp. 250–260). https://doi.org/10.1007/978-981-16-7476-1_23
14. Mahastama, A. W., & Krisnawati, L. D. (2020). Optical character recognition for printed Javanese script using projection profile segmentation and nearest centroid classifier. In *2020 Asia Conference on Computers and Communications (ACCC)* (pp. 52–56). <https://doi.org/10.1109/ACCC51160.2020.9347895>
15. Maulana, M. I. (2024). Menurunnya minat tulisan aksara Jawa di lingkup mahasiswa Sejarah Peradaban Islam UIN Sunan Ampel Surabaya. *HEURISTIK: Jurnal Pendidikan Sejarah*, 3(2), 62–76. <https://doi.org/10.31258/hjps.3.2.62-76>
16. Muhdalifah, M. F. (2022). Pooling comparison in CNN architecture for Javanese script classification. *International Journal of Informatics and Computation*, 3(2), 15. <https://doi.org/10.35842/ijicom.v3i2.30>
17. Nugroho, R. P. (2024). *Aksara Jawa/Hanacaraka* [Dataset]. Kaggle. <https://www.kaggle.com/datasets/vzrengamani/hanacaraka/>

18. Priyambodo, A., Martius Apun Heses, & Kristiawan Nurdianto. (2024). Klasifikasi gambar aksara Jawa dengan optimasi parameter KNN menggunakan GridSearchCV. *Jurnal Cakrawala Informasi*, 4(2), 103–120. <https://doi.org/10.54066/jci.v4i2.497>
19. Rahmawati, A. A., Muhaimin, A., & Prasetya, D. A. (2024). Classification of Javanese nglegena script using complex-valued neural network. *JIKO (Jurnal Informatika dan Komputer)*, 7(1), 30–35. <https://doi.org/10.33387/jiko.v7i1.7808>
20. Rasyidi, M. A., Bariyah, T., Riskajaya, Y. I., & Septyani, A. D. (2021). Classification of handwritten Javanese script using random forest algorithm. *Bulletin of Electrical Engineering and Informatics*, 10(3), 1308–1315. <https://doi.org/10.11591/eei.v10i3.3036>
21. Saidulu, N., Monsley, K. A., Yadav, K. S., & Laskar, R. H. (2022). Exploration of deep convolutional neural networks (via transfer learning) for handwritten character recognition. In *2022 Second International Conference on Power, Control and Computing Technologies (ICPC2T)* (pp. 1–6). <https://doi.org/10.1109/ICPC2T53885.2022.9776795>
22. Sudewo, E. D. B., Biddinika, M. K., & Fadlil, A. (2024). Javanese script Hanacaraka character prediction with ResNet-18 architecture. *JURTEKSI (Jurnal Teknologi dan Sistem Informasi)*, 10(2), 363–370. <https://doi.org/10.33330/jurteksi.v10i2.3017>
23. Susanto, A., Sari, C. A., Rachmawanto, E. H., Mulyono, I. U. W., & Mohd Yaacob, N. (2024). A comparative study of Javanese script classification with GoogleNet, DenseNet, ResNet, VGG16 and VGG19. *Scientific Journal of Informatics*, 11(1), 31–40. <https://doi.org/10.15294/sji.v11i1.47305>
24. Wawan, Pamungkasari, P. D., & Sholihati, I. (2024). Hyperparameter tuning and preprocessing techniques for optimizing Javanese scripts classification. In *2024 8th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)* (pp. 29–34). <https://doi.org/10.1109/ICITISEE63424.2024.10730205>