

# Klasifikasi Citra Aksara Tradisional Kaganga Bengkulu Menggunakan Optimasi Arsitektur ResNet50

Vina Ayumi

Fakultas Teknik dan Informatika, Universitas Dian Nusantara, Indonesia

vina.ayumi@dosen.undira.ac.id

## Article Info

### Article history:

Received, 2025-11-21

Revised, 2025-12-01

Accepted, 2025-12-09

### Kata Kunci:

Kaganga,  
ResNet50,  
Transfer Learning,  
Hyperparameter Tuning,  
Regularisasi,  
Batch Size

### Keywords:

Kaganga,  
ResNet50,  
Transfer Learning,  
Hyperparameter Tuning,  
Regulatization,  
Batch Size

## ABSTRAK

Penelitian ini bertujuan untuk menganalisis kinerja model ResNet50 berbasis transfer learning dalam mengklasifikasikan 19 kelas aksara Kaganga, sekaligus mengevaluasi pengaruh penerapan teknik regularisasi L1, L2, dan dropout terhadap kemampuan generalisasi model dalam meminimalkan *overfitting*. Selain itu, penelitian ini juga menguji dampak variasi *batch size* (16, 32, dan 64) terhadap stabilitas pelatihan dan performa model. Eksperimen dilakukan dengan membekukan lapisan awal ResNet50 sebagai ekstraktor fitur, kemudian memodifikasi lapisan akhir untuk tugas klasifikasi. Evaluasi kinerja model menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix* pada data pengujian. Hasil penelitian menunjukkan bahwa seluruh konfigurasi model mampu mencapai akurasi pelatihan dan validasi yang tinggi. Namun, kombinasi regularisasi L2 dengan *batch size* 32 memberikan kinerja terbaik dengan *testing accuracy* sebesar 86,10%, yang menunjukkan kemampuan generalisasi paling optimal dibandingkan konfigurasi lain. Sementara itu, *batch size* 64 menghasilkan penurunan akurasi yang lebih nyata, sehingga kurang efektif untuk dataset ini. Hasil penelitian ini menunjukkan bahwa pemilihan regularisasi dan batch size yang tepat memiliki peran penting dalam meningkatkan stabilitas pembelajaran dan akurasi klasifikasi citra aksara tradisional.

## ABSTRACT

This study aimed to analyze the performance of the ResNet50 model based on transfer learning in classifying 19 classes of Kaganga script, while also evaluating the effect of applying L1, L2, and dropout regularization techniques on the model's generalization ability in minimizing overfitting. In addition, the study examined the impact of varying batch sizes (16, 32, and 64) on training stability and overall model performance. The experiments were conducted by freezing the initial layers of ResNet50 as a feature extractor and modifying the final layers for the classification task. Model performance was evaluated using accuracy, precision, recall, F1-score, and confusion matrix metrics on the test dataset. The results showed that all model configurations achieved high training and validation accuracy. However, the combination of L2 regularization with a batch size of 32 yielded the best performance with a testing accuracy of 86.10%, indicating the most optimal generalization capability compared to other configurations. Meanwhile, the use of batch size 64 resulted in a more noticeable decrease in accuracy, making it less effective for this dataset. These findings indicated that the appropriate selection of regularization techniques and batch size played an important role in improving training stability and classification accuracy for traditional script image recognition.

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-nc-nd/4.0/) license.



## Penulis Korespondensi:

Vina Ayumi,  
Fakultas Teknik dan Informatika,  
Universitas Dian Nusantara, Indonesia  
Email: vina.ayumi@dosen.undira.ac.id

## 1. PENDAHULUAN

Aksara Rejang atau Kaganga merupakan salah satu aksara tradisional yang berkembang di wilayah Sumatera bagian Selatan, khususnya di Bengkulu. Aksara ini terdiri atas 19 huruf inti, yaitu Ka, Ga, Nga, Ta, Da, Na, Pa, Ba, Ma, Ca, Ja, Nya, Ya, Ra, La, Sa, Wa, Ha, dan A (vokal tunggal). Keberadaan aksara Kaganga memiliki nilai historis, linguistik, dan kultural yang penting karena menjadi identitas lokal masyarakat Rejang. Namun, perubahan sosial dan perkembangan teknologi informasi menyebabkan penggunaan aksara tradisional ini semakin menurun. Upaya digitalisasi dan otomasi pengenalan aksara menjadi salah satu strategi pelestarian yang relevan, khususnya melalui teknologi pengolahan citra berbasis kecerdasan buatan [1], [2], [3].

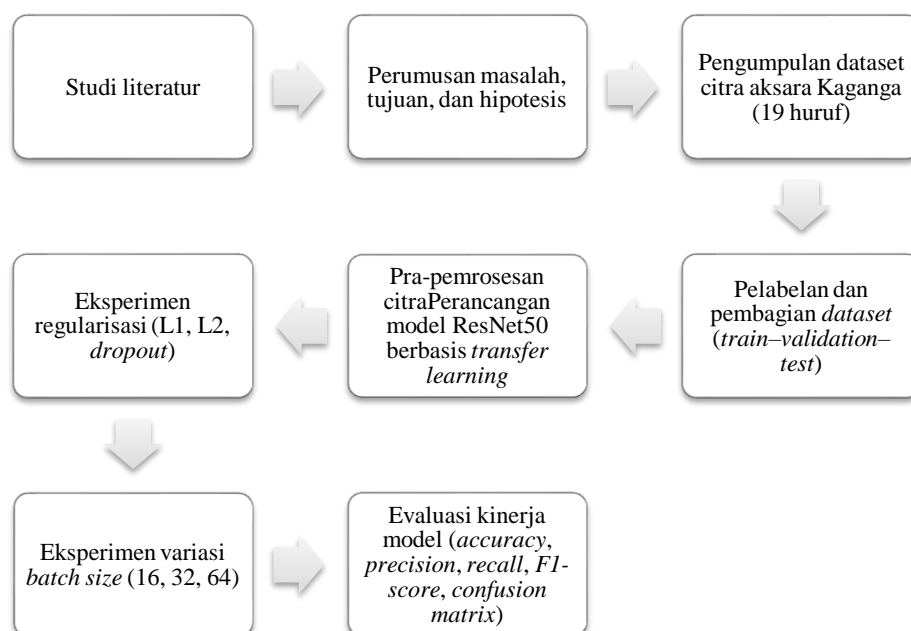
Perkembangan deep learning, terutama *Convolutional Neural Network (CNN)*, telah memberikan kontribusi besar dalam pengenalan pola dan klasifikasi citra aksara [4], [5], [6], [7], [8], [9], [10], [11]. Salah satu arsitektur CNN yang banyak digunakan adalah ResNet50, yang memiliki kemampuan generalisasi yang baik melalui konsep residual learning. Namun, kinerja ResNet50 dalam pengenalan citra aksara tradisional masih dapat ditingkatkan, khususnya ketika berhadapan dengan variasi bentuk tulisan, kondisi pencahayaan, *noise*, serta keterbatasan jumlah data. Oleh karena itu, diperlukan strategi optimasi model agar akurasi klasifikasi menjadi lebih optimal.

Beberapa teknik optimasi yang dapat diterapkan meliputi regularisasi L1 dan L2 untuk mengurangi *overfitting* melalui pengendalian bobot model, serta *dropout* guna meningkatkan kemampuan generalisasi jaringan. Selain itu, penentuan *batch size* yang tepat, seperti 16, 32, atau 64, berperan penting dalam stabilitas proses pembelajaran dan efektivitas konvergensi model. Kombinasi antara teknik regularisasi dan pengaturan *batch size* diharapkan mampu meningkatkan kinerja ResNet50 dalam mengenali 19 huruf inti aksara Kaganga [12], [13], [14], [15], [16].

Berdasarkan penjelasan di atas, penelitian ini difokuskan pada optimasi ResNet50 untuk klasifikasi citra aksara tradisional Kaganga melalui penerapan regularisasi L1, L2, dropout, serta variasi batch size. Penelitian ini diharapkan dapat mendukung pengembangan sistem pengenalan aksara berbasis deep learning, tetapi juga mendukung upaya pelestarian warisan literasi lokal melalui digitalisasi aksara tradisional.

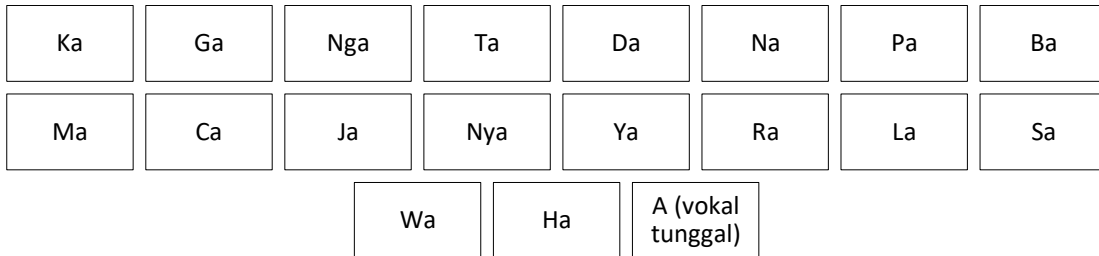
## 2. METODE PENELITIAN

Pada tahap awal dilakukan penelusuran referensi terkait aksara Kaganga, teknik pengenalan citra, *Convolutional Neural Network (CNN)*, serta arsitektur ResNet50, termasuk kajian mengenai regularisasi L1, L2, *dropout*, konsep *batch size*, dan penelitian terdahulu mengenai klasifikasi aksara tradisional. Hasil kajian ini menjadi dasar dalam merumuskan permasalahan utama, yaitu bagaimana mengoptimasi ResNet50 agar mampu mengklasifikasikan 19 huruf Kaganga secara lebih akurat. Pada tahap yang sama juga ditetapkan tujuan penelitian, dirumuskan hipotesis, serta ditentukan indikator kinerja model seperti akurasi, *precision*, *recall*, dan *F1-score* sebagai ukuran keberhasilan sistem klasifikasi yang dikembangkan. Adapun tahap penelitian dapat dilihat pada Gambar 1.



Gambar 1 Tahap Penelitian

Pengumpulan dan persiapan data dilakukan dengan menghimpun dataset citra aksara Kaganga yang terdiri dari 19 huruf inti, yaitu Ka, Ga, Nga, Ta, Da, Na, Pa, Ba, Ma, Ca, Ja, Nya, Ya, Ra, La, Sa, Wa, Ha, dan A. Seluruh citra diberi label sesuai kelasnya, kemudian dipersiapkan dalam format yang sesuai untuk proses pelatihan model, termasuk normalisasi dan pembagian data ke dalam *subset training*, *validation*, dan *testing*.



Gambar 2 Kelas Data Penelitian

Pada tahap perancangan model, ResNet50 diimplementasikan dengan pendekatan *transfer learning*. Lapisan awal model dapat dibekukan untuk mempertahankan ekstraksi fitur generik, sementara lapisan akhir dimodifikasi agar sesuai dengan 19 kelas aksara Kaganga. Selain itu, diterapkan teknik regularisasi berupa L1, L2, serta *dropout layer* sebagai variabel eksperimen untuk meningkatkan kemampuan generalisasi model dan meminimalkan *overfitting*. Eksperimen dilakukan secara terkontrol dengan menguji kombinasi regulasi tersebut serta menggunakan variasi *batch size* 16, 32, dan 64.

Tahap evaluasi dilakukan dengan menguji performa model pada dataset *testing*. Pengukuran kinerja dilakukan menggunakan beberapa metrik evaluasi, yaitu *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix* untuk melihat distribusi prediksi antar kelas. Hasil evaluasi ini digunakan untuk menganalisis pengaruh kombinasi regularisasi dan variasi *batch size* terhadap kinerja model ResNet50 dalam mengklasifikasikan aksara Kaganga.

### 3. HASIL DAN ANALISIS

Tujuan eksperimen dalam penelitian ini adalah untuk menguji kinerja model ResNet50 berbasis *transfer learning* dalam melakukan klasifikasi 19 kelas aksara Kaganga, sekaligus menganalisis pengaruh penerapan teknik regularisasi L1, L2, dan *dropout* terhadap kemampuan generalisasi model dalam meminimalkan *overfitting*. Selain itu, penelitian ini juga bertujuan untuk mengevaluasi dampak variasi *batch size* (16, 32, dan 64) terhadap stabilitas pelatihan dan performa akhir model. Kombinasi antara skema regularisasi dan *batch size* dibandingkan secara sistematis untuk memperoleh konfigurasi model ResNet50 yang paling optimal. Kinerja model diukur menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix* untuk melihat distribusi prediksi pada setiap kelas aksara Kaganga. Hasil eksperimen akurasi model ResNet50 dengan *batch size* 16 dilihat pada **Tabel 1**.

Tabel 1 Hasil Akurasi Model ResNet50 dengan *Batch Size* 16

Regularisasi	Training Accuracy	Validation Accuracy	Testing Accuracy
Tanpa Regularisasi	98.25%	94.85%	84.60%
L1	97.10%	95.20%	85.05%
L2	97.45%	95.78%	85.30%
Dropout	96.95%	95.15%	85.00%

Kinerja model ResNet50 dengan *batch size* 16 menunjukkan bahwa seluruh skema regularisasi mampu menghasilkan akurasi pelatihan dan validasi yang tinggi, yaitu di atas 96% untuk training dan sekitar 95% untuk validation. Namun, terdapat penurunan akurasi pada tahap pengujian (*testing*), yang berkisar antara 84.60% hingga 85.30%. Kondisi ini mengindikasikan adanya gejala *overfitting* ringan, di mana model belajar sangat baik pada data pelatihan namun performanya sedikit menurun ketika diuji pada data baru. Jika dibandingkan, penggunaan regularisasi L2 menghasilkan akurasi pengujian tertinggi sebesar 85.30%, diikuti oleh L1 sebesar 85.05%, *dropout* sebesar 85.00%, dan tanpa regularisasi sebesar 84.60%. Untuk hasil eksperimen akurasi model ResNet50 dengan *batch size* 32 dilihat pada **Tabel 2**.

Tabel 2 Hasil Akurasi Model ResNet50 dengan *Batch Size* 32

Regularisasi	Training Accuracy	Validation Accuracy	Testing Accuracy
Tanpa Regularisasi	97.30%	95.65%	85.40%
L1	96.85%	95.90%	85.75%
L2	96.92%	96.25%	86.10%
Dropout	96.55%	95.88%	85.80%


Berdasarkan hasil akurasi model ResNet50 dengan *batch size* 32, terlihat bahwa seluruh konfigurasi model mampu mencapai kinerja pelatihan dan validasi yang tinggi, dengan *training accuracy* berada di kisaran 96–97% dan *validation accuracy* sekitar 95–96%. Pada tahap pengujian, performa model tetap stabil dengan akurasi *testing* antara 85.40% hingga 86.10%, yang menunjukkan kemampuan generalisasi yang relatif baik terhadap data aksara Kaganga yang tidak dilibatkan dalam proses pelatihan. Jika dibandingkan antar skema regularisasi, penggunaan L2 kembali memberikan hasil terbaik dengan akurasi pengujian tertinggi sebesar 86.10%, disusul *dropout* sebesar 85.80% dan L1 sebesar 85.75%. Menariknya, akurasi tanpa regularisasi justru berada di posisi terendah, yaitu 85.40%, sehingga semakin menegaskan bahwa regularisasi berkontribusi dalam menekan overfitting dan meningkatkan stabilitas kinerja model. Dibandingkan dengan *batch size* 16, penggunaan *batch size* 32 cenderung menghasilkan akurasi pengujian yang sedikit lebih tinggi, sehingga dapat disimpulkan bahwa *batch size* yang lebih besar memberikan proses pembaruan bobot yang lebih stabil. Untuk hasil eksperimen akurasi model ResNet50 dengan *batch size* 64 dilihat pada **Tabel 2**.

Tabel 3 Hasil Akurasi Model ResNet50 dengan *Batch Size* 64

Regularisasi	Training Accuracy	Validation Accuracy	Testing Accuracy
Tanpa Regularisasi	95.85%	93.80%	83.55%
L1	95.40%	94.10%	83.90%
L2	95.55%	94.65%	84.35%
Dropout	95.10%	94.25%	84.00%

Berdasarkan hasil akurasi model ResNet50 dengan *batch size* 64, terlihat bahwa kinerja model masih tergolong baik pada tahap pelatihan dan validasi, dengan *training accuracy* berada di kisaran 95% dan *validation accuracy* sekitar 93–94%. Namun, jika dibandingkan dengan *batch size* 16 dan 32, terjadi penurunan kinerja yang cukup jelas pada tahap pengujian, di mana *testing accuracy* hanya berada pada rentang 83.55% hingga 84.35%. Hal ini menunjukkan bahwa penggunaan *batch size* yang lebih besar cenderung membuat proses pembaruan bobot menjadi kurang sensitif terhadap variasi data, sehingga mengurangi kemampuan model dalam mengenali pola fitur aksara Kaganga pada data yang belum pernah dilihat sebelumnya. Jika dilihat berdasarkan skema regularisasi, L2 kembali memberikan performa terbaik dengan akurasi pengujian tertinggi sebesar 84.35%, diikuti *dropout* sebesar 84.00% dan L1 sebesar 83.90%, sedangkan tanpa regularisasi menghasilkan akurasi terendah yaitu 83.55%. Pola ini mengonfirmasi bahwa regularisasi tetap berperan penting dalam membantu model menjaga kemampuan generalisasi.

Berdasarkan ketiga hasil eksperimen, dapat disimpulkan bahwa kinerja terbaik dicapai oleh model ResNet50 dengan *batch size* 32, khususnya pada konfigurasi regularisasi L2 yang menghasilkan *testing accuracy* tertinggi sebesar 86.10%. kombinasi ResNet50 + *batch size* 32 + regularisasi L2 dapat dianggap sebagai konfigurasi paling optimal dalam melakukan klasifikasi aksara Kaganga pada eksperimen ini. Adapun hasil eksperimen per epoch untuk model ResNet50 + *batch size* 32 + regularisasi L2 dapat dilihat pada Gambar 3.



Gambar 3 Grafik akurasi ResNet50 dengan L2 dan *batch size* 32

Jika dibandingkan, penggunaan *batch size* 16 menghasilkan akurasi pengujian yang sedikit lebih rendah (maksimum 85.30%), sedangkan *batch size* 64 justru menunjukkan penurunan akurasi yang lebih nyata

(maksimum 84.35%). Pola ini menunjukkan bahwa *batch size* 32 memberikan keseimbangan yang lebih optimal antara stabilitas pembaruan bobot dan kemampuan generalisasi model. Selain itu, regularisasi L2 secara konsisten menjadi konfigurasi paling efektif pada seluruh variasi *batch size*, yang mengindikasikan bahwa penalti bobot L2 mampu mengontrol kompleksitas model tanpa mengurangi kemampuan model dalam mengekstraksi fitur penting pada aksara Kaganga.

#### 4. KESIMPULAN

Berdasarkan rangkaian eksperimen yang telah dilakukan, dapat disimpulkan bahwa penerapan *transfer learning* pada model ResNet50 dapat melakukan klasifikasi 19 kelas aksara Kaganga. Seluruh konfigurasi model menunjukkan akurasi pelatihan dan validasi yang tinggi, namun tetap terdapat indikasi *overfitting* ringan yang berhasil ditekan melalui penerapan teknik regularisasi. Hasil penelitian menunjukkan bahwa kombinasi regularisasi L2 dan *batch size* 32 memberikan performa terbaik, dengan nilai testing *accuracy* tertinggi sebesar 86,10%, sehingga dapat dinyatakan sebagai konfigurasi paling optimal dalam meningkatkan kemampuan generalisasi model. Sebaliknya, penggunaan *batch size* yang terlalu kecil (16) atau terlalu besar (64) menghasilkan performa pengujian yang relatif lebih rendah, yang menunjukkan bahwa pemilihan *batch size* berperan penting dalam stabilitas proses pembelajaran. Secara konsisten, regularisasi L2 terbukti paling efektif dibandingkan L1 dan dropout dalam menjaga keseimbangan antara kompleksitas model dan akurasi prediksi. Penelitian ini menyimpulkan bahwa kombinasi arsitektur ResNet50, regularisasi L2, dan *batch size* 32 merupakan pendekatan yang baik untuk pengenalan citra aksara Kaganga, serta dapat menjadi rujukan dalam pengembangan model klasifikasi aksara tradisional Nusantara pada penelitian selanjutnya.

#### UCAPAN TERIMA KASIH

Terima kasih kepada Lembaga Riset dan Pengabdian kepada Masyarakat (LRPM) Universitas Dian Nusantara (UNDIRA) yang telah mendanai penelitian ini melalui skema penelitian internal. Terima kasih juga kepada Bapak Erwin Dwika Putra yang sudah menyediakan dataset untuk penelitian ini.

#### REFERENSI

- [1] H. A. Adhini and K. Somantri, "Exploration of Kaganga Batik Painting Techniques On Lantung Bark Material with The Application Of Applique and Raffia Embroidery Techniques in Ready-To-Wear Deluxe," in *Indonesian Textile Conference*, 2022, pp. 177–204.
- [2] E. Anggelita and U. Khair, "Implementasi Muatan Lokal Aksara Kaganga Rejang pada Siswa Kelas III SDN 72 Rejang Lebong," 2023, *e-theses.iaincurup.ac.id*.
- [3] E. P. Purwandari, D. Andreswar, and S. Sarwono, "Mobile Kaganga Language as Cultural Literacy and Learning Media for Elementary Schools," *Ilkogr. Online*, vol. 20, no. 1, 2021.
- [4] U. Rusmawan and I. Mulya, "Sistem Informasi Koperasi Menggunakan Metode Rapid Application Development (RAD)," *J. Inf. Syst. Technol*, vol. 1, no. 1, pp. 1–10, 2022.
- [5] D. Ramayanti, Y. Jumaryadi, D. M. Gufron, and D. D. Ramadha, "Sistem Keamanan Perumahan Menggunakan Face Recognition," *TIN Terap. Inform. Nusant.*, vol. 3, no. 12, pp. 486–496, 2023.
- [6] H. Noprisson, E. Ermatita, A. Abdiansah, V. Ayumi, M. Purba, and H. Setiawan, "Fine-Tuning Transfer Learning Model in Woven Fabric Pattern Classification," *Int. J. Innov. Comput. Inf. Control*, vol. 18, no. 06, p. 1885, 2022, doi: <http://doi.org/10.24507/ijicic.18.06.1885>.
- [7] V. Ayumi, "Performance Evaluation of Support Vector Machine Algorithm for Human Gesture Recognition," *Int. J. Sci. Res. Sci. Eng. Technol.*, vol. 7, no. 6, pp. 204–210, 2020.
- [8] A. Ratnasari, Y. Jumaryadi, and G. Gata, "Sistem Pakar Deteksi Penyakit Ginekologi Menggunakan Metode Forward Chaining," *Resolusi Rekayasa Tek. Inform. dan Inf.*, vol. 3, no. 5, pp. 321–327, 2023.
- [9] B. Y. Geni, A. Supriyadi, H. Khotimah, and W. I. Yanti, "Rancang Bangun Company Profile Berbasis Web Menggunakan Metode Waterfall (Studi Kasus: APM Frozen Food)," *J. RESTIKOM Ris. Tek. Inform. dan Komput.*, vol. 6, no. 1, pp. 75–85, 2024.
- [10] S. Hesti, "The effects of relational social capital and technological factors on knowledge sharing in an online community," *Int. J. Innov. Creat. Chang.*, vol. 13, no. 4, 2020.
- [11] I. Kamil, M. Ariani, and I. A. Irawan, "The influence of lifestyle and financial literacy on online paylater system and its impact on spending behavior," *J. Econ. Bus. Lett.*, vol. 4, no. 2, pp. 51–62, 2024.
- [12] Y. Xu *et al.*, "Dropout Reduces Underfitting," *arXiv Learn.*, vol. 2022, no. 4, pp. 679–684, 2022, doi: 10.1155/2022/8220453.
- [13] B. J. Lengerich, E. P. Xing, and R. Caruana, "Dropout as a Regularizer of Interaction Effects.," *arXiv Learn.*, 2021, [Online]. Available: <https://arxiv.org/pdf/2007.00823.pdf>
- [14] 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.
- [15] E. D. Putra, E. Ermatita, and A. Abdiansah, “Handwritten Kaganga script classification using deep learning and image fusion,” *Bull. Electr. Eng. Informatics*, vol. 14, no. 2, pp. 1290–1297, 2025.
- [16] E. D. Putra, E. Ermatita, and A. Abdiansyah, “The Model Regularized CLAHE-CNN for the Traditional Script Character of Kaganga Bengkulu Recognition,” in *2024 Ninth International Conference on Informatics and Computing (ICIC)*, IEEE, 2024, pp. 1–5.