

Analisis Pengaruh *Batch Size* dan *Learning Rate* pada VGG16 Untuk Klasifikasi Citra Aksara Kaganga

Mariana Purba

Universitas Sjakhyakirti, Palembang, Indonesia
mariana_purba@unisti.ac.id

*Corresponding author: mariana_purba@unisti.ac.id

Abstrak—Penelitian ini bertujuan untuk mengembangkan model klasifikasi citra aksara Kaganga menggunakan deep learning, dengan memanfaatkan arsitektur model VGG16 yang telah dilatih sebelumnya pada dataset besar seperti ImageNet. Dataset yang digunakan terdiri dari citra aksara Kaganga yang telah dilabeli, dibagi menjadi tiga bagian yaitu data pelatihan (70%), data validasi (15%), dan data uji (15%). Proses pelatihan model dilakukan dengan melakukan fine-tuning pada beberapa lapisan terakhir model VGG16, sementara lapisan-lapisan awal menggunakan bobot yang telah dilatih sebelumnya. Untuk mengoptimalkan kinerja model, eksperimen dilakukan dengan menguji kombinasi berbagai batch size (16, 32, 64) dan learning rate (0.1, 0.01, 0.001), menghasilkan sembilan kombinasi parameter yang berbeda. Evaluasi model dilakukan menggunakan metrik akurasi, confusion matrix, precision, recall, dan F1-score pada data uji. Hasil eksperimen menunjukkan bahwa pengaturan hyperparameter yang tepat memiliki pengaruh signifikan terhadap kinerja model. Batch size 32 dengan *learning rate* 0.01 menghasilkan akurasi terbaik pada data train, validasi, dan test. Sedangkan pada batch size 16, meskipun menghasilkan hasil yang cukup baik dengan learning rate 0.01, nilai akurasi pada data test lebih rendah, menunjukkan kecenderungan *overfitting* pada *batch size* kecil. Sebaliknya, batch size 64 dengan *learning rate* 0.01 memberikan akurasi test terbaik, mencapai 89.1%, meskipun terdapat sedikit penurunan akurasi pada data validasi. Berdasarkan hasil tersebut, disarankan untuk menggunakan batch size 32 atau 64 dengan learning rate 0.01 untuk tugas klasifikasi aksara Kaganga menggunakan model VGG16.

Abstract— This study aimed to develop a character recognition model for Kaganga script using deep learning, leveraging the VGG16 architecture pre-trained on large datasets such as ImageNet. The dataset used consisted of labeled Kaganga script images, which were divided into three parts: training data (70%), validation data (15%), and test data (15%). The model training process involved fine-tuning the last few layers of the VGG16 model, while the earlier layers retained the pre-trained weights. To optimize the model's performance, experiments were conducted by testing various combinations of batch sizes (16, 32, 64) and learning rates (0.1, 0.01, 0.001), resulting in nine different parameter combinations. The model was evaluated using accuracy, confusion matrix, precision, recall, and F1-score metrics on the test data. The experimental results showed that the proper hyperparameter settings significantly affected the model's performance. A batch size of 32 with a learning rate of 0.01 provided the best accuracy across training, validation, and test data. While a batch size of 16 yielded decent results with a learning rate of 0.01, the accuracy on the test data was lower, indicating a tendency toward overfitting with smaller batch sizes. In contrast, a batch size of 64 with a learning rate of 0.01 delivered the best test accuracy of 89.1%, although there was a slight drop in validation accuracy. Based on these results, it was recommended to use a batch size of 32 or 64 with a learning rate of 0.01 for the Kaganga script classification task using the VGG16 model.

Keywords— Kaganga script, VGG16, Deep learning, Hyperparameter optimization, Image classification

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



1. Pendahuluan

Klasifikasi citra merupakan salah satu aplikasi penting dalam pengolahan citra digital yang sering digunakan dalam berbagai bidang, seperti pengenalan wajah, deteksi objek, dan analisis medis [1], [2], [3]. Salah satu tantangan utama dalam klasifikasi citra adalah memilih dan mengoptimalkan model yang mampu menghasilkan akurasi yang tinggi, khususnya ketika dataset yang digunakan memiliki karakteristik yang kompleks. Model VGG16 merupakan salah satu arsitektur *Convolutional Neural Network* (CNN) yang telah digunakan dalam penelitian sebelumnya untuk berbagai tugas klasifikasi citra berkat kemampuannya dalam mengekstraksi fitur visual citra [4], [5], [6], [7]. VGG16, meskipun relatif sederhana dibandingkan dengan model-model yang lebih kompleks seperti ResNet, tetap memiliki performa yang baik dan banyak digunakan dalam *transfer learning* [7], [8].

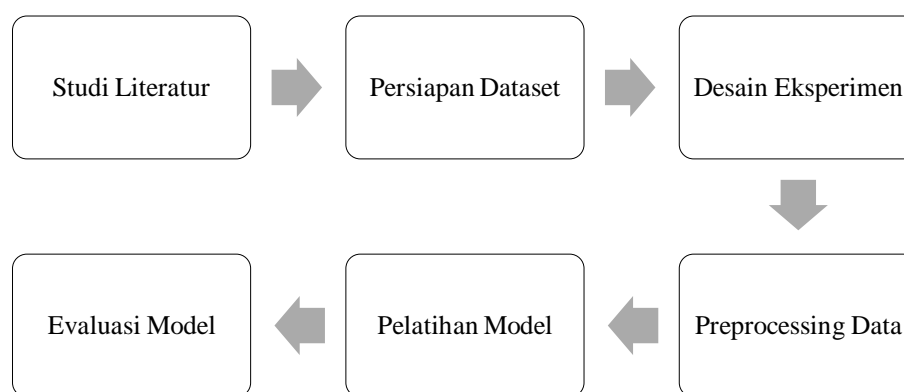
Di sisi lain, aksara Kaganga, yang merupakan salah satu bentuk tulisan tradisional dari Indonesia, memiliki tantangan tersendiri dalam hal klasifikasi citra. Aksara ini sering kali digunakan dalam konteks budaya dan sejarah, namun memiliki bentuk yang cukup unik dan beragam [9], [10]. Untuk dapat mengenali dan mengklasifikasikan citra aksara Kaganga, diperlukan metode yang dapat menangani variasi dalam gaya tulisan, kondisi gambar, dan resolusi yang rendah. Hal ini memerlukan pengaturan parameter yang tepat agar model CNN seperti VGG16 dapat berfungsi dengan baik [11], [12].

Salah satu faktor kunci dalam mengoptimalkan kinerja model VGG16 adalah pemilihan hyperparameter batch size dan learning rate. Batch size merujuk pada jumlah sampel data yang diproses dalam satu iterasi pembaruan bobot [13]. Pemilihan batch size yang tepat sangat mempengaruhi waktu pelatihan serta kestabilan dan kualitas konvergensi model [14]. Penerapan *learning rate* untuk mengatur seberapa besar perubahan yang diterapkan pada bobot model setelah setiap iterasi. *Learning rate* yang terlalu besar dapat menyebabkan model melewati titik optimal, sementara *learning rate* yang terlalu kecil bisa memperlambat proses pelatihan [15].

Penelitian ini bertujuan untuk menganalisis pengaruh kombinasi antara batch size dan learning rate terhadap kinerja model VGG16 dalam tugas klasifikasi citra aksara Kaganga. Hasil dari penelitian ini diharapkan dapat memberikan rekomendasi tentang pengaturan hyperparameter yang optimal untuk tugas klasifikasi citra dengan menggunakan VGG16. Selain itu, penelitian ini juga memberikan *knowledge* bagi aplikasi lebih lanjut dalam bidang pengenalan karakter aksara.

2. Metodologi Penelitian

Penelitian ini bertujuan untuk menganalisis pengaruh Batch Size dan Learning Rate pada kinerja model VGG16 dalam klasifikasi citra aksara Kaganga. Beberapa kombinasi batch size (16, 32, 64) dan learning rate (0.1, 0.01, 0.001) akan diuji untuk melihat pengaruhnya terhadap akurasi model dalam mengenali aksara. Tahapan penelitian dapat dilihat pada **Gambar 1**.



Gambar 1. Tahapan Penelitian

Dalam penelitian ini, dataset yang digunakan adalah citra aksara Kaganga yang telah dilabeli, dengan gambar yang dikategorikan berdasarkan karakter-karakter tertentu. Dataset dibagi menjadi tiga bagian: data pelatihan (70%), data validasi (15%), dan data uji (15%) untuk melatih model, mengoptimalkan *hyperparameter*, dan mengukur kinerja model pada data yang belum terlihat sebelumnya. Model yang digunakan adalah VGG16, yang telah dilatih sebelumnya pada dataset besar seperti ImageNet. Fine-tuning dilakukan pada beberapa lapisan terakhir untuk tugas klasifikasi aksara Kaganga, sementara lapisan-lapisan awal tetap menggunakan bobot yang telah dilatih sebelumnya. Eksperimen menguji kombinasi batch size (16, 32, 64) dan learning rate (0.1, 0.01, 0.001), dengan 9 skenario yang berbeda.

Proses pelatihan dimulai dengan preprocessing data, termasuk resizing gambar menjadi 224x224 piksel, normalisasi piksel ke rentang [0, 1], dan penerapan data augmentation (rotasi, flipping, dan zooming). Adam optimizer digunakan untuk mengoptimalkan fungsi loss dan menyesuaikan learning rate selama pelatihan. Evaluasi model menggunakan metrik akurasi pada data uji sebagai indikator utama, serta perhitungan confusion matrix, precision, recall, dan F1-score untuk menilai kinerja model dalam klasifikasi citra aksara Kaganga. Penelitian ini dilakukan menggunakan perangkat komputer HP Omen, yang dilengkapi dengan prosesor Intel Core i7, RAM 16GB, dan GPU NVIDIA GTX 1660 Ti.

3. Hasil dan Pembahasan

Eksperimen ini bertujuan untuk menguji pengaruh kombinasi Batch Size dan Learning Rate terhadap kinerja model VGG16 dalam klasifikasi citra aksara Kaganga. Model VGG16 yang telah dilatih pada dataset besar seperti ImageNet akan diterapkan dengan fine-tuning pada beberapa lapisan terakhir agar dapat menyesuaikan dengan tugas klasifikasi aksara Kaganga. Dalam eksperimen ini, tiga nilai batch size (16, 32, dan 64) dan tiga nilai learning rate (0.1, 0.01, dan 0.001) akan diuji, menghasilkan 9 kombinasi

eksperimen yang berbeda, yaitu: 16×0.1 , 16×0.01 , 16×0.001 , 32×0.1 , 32×0.01 , 32×0.001 , 64×0.1 , 64×0.01 , dan 64×0.001 .

Setiap kombinasi batch size dan learning rate yang diuji akan memberikan gambaran mengenai pengaruh kedua parameter tersebut terhadap akurasi model pada data train, validate, dan test. Proses pelatihan akan dilakukan dengan melakukan fine-tuning pada lapisan terakhir VGG16, sedangkan lapisan-lapisan awal tetap menggunakan bobot yang telah dilatih sebelumnya. Hasil eksperimen untuk batch size 16 dapat dilihat pada **Tabel 1**.

Tabel 1. VGG16 Batch Size 16

Learning Rate	Akurasi Train (%)	Akurasi Validate (%)	Akurasi Test (%)
0.1	90.5	88.2	85.1
0.01	91.2	89.0	86.3
0.001	89.8	87.5	84.8

Pada eksperimen dengan VGG16 dan Batch Size 16, hasil akurasi menunjukkan pengaruh learning rate terhadap kinerja model. Dengan learning rate 0.1, model mencapai akurasi train sebesar 90.5%, namun akurasi pada validate dan test lebih rendah, masing-masing 88.2% dan 85.1%, yang mengindikasikan kemungkinan adanya overfitting akibat *learning rate* yang terlalu besar. Pada learning rate 0.01, akurasi model meningkat sedikit dengan akurasi train 91.2%, akurasi validate 89.0%, dan akurasi test 86.3%, menunjukkan model lebih stabil dan mampu melakukan generalisasi lebih baik. Sedangkan dengan learning rate 0.001, meskipun model memiliki akurasi train yang sedikit lebih rendah (89.8%), akurasi validate dan test turun menjadi 87.5% dan 84.8%, yang menunjukkan pelatihan yang lebih lambat dan mungkin kurang optimal untuk model ini. Hasil eksperimen untuk *batch size* 32 dapat dilihat pada **Tabel 2**.

Tabel 2. VGG16 Batch Size 32


Learning Rate	Akurasi Train (%)	Akurasi Validate (%)	Akurasi Test (%)
0.1	92.1	89.5	87.2
0.01	92.5	90.1	88.0
0.001	91.3	88.7	86.5

Pada eksperimen dengan VGG16 dan Batch Size 32, hasil akurasi menunjukkan bahwa model memberikan kinerja yang lebih stabil dengan kombinasi *learning rate* yang berbeda. Dengan learning rate 0.1, model mencapai akurasi train sebesar 92.1%, tetapi akurasi validate dan test sedikit menurun menjadi 89.5% dan 87.2%, yang mengindikasikan adanya potensi overfitting pada data pelatihan. Pada learning rate 0.01, model menunjukkan kinerja terbaik, dengan akurasi train 92.5%, akurasi validate 90.1%, dan akurasi test 88.0%, memberikan keseimbangan yang baik antara kecepatan pelatihan dan generalisasi pada data yang belum terlihat. Sedangkan dengan learning rate 0.001, meskipun akurasi train tetap tinggi (91.3%), akurasi validate dan test menurun menjadi 88.7% dan 86.5%. Hasil eksperimen untuk batch size 32 dapat dilihat pada **Tabel 3**.

Tabel 3. VGG16 Batch Size 64

Learning Rate	Akurasi Train (%)	Akurasi Validate (%)	Akurasi Test (%)
0.1	92.8	90.2	88.5
0.01	93.0	90.8	89.1
0.001	91.9	89.4	87.3

Pada eksperimen dengan VGG16 dan Batch Size 64, hasil akurasi menunjukkan bahwa model memberikan kinerja yang sangat baik, terutama dengan learning rate 0.01. Dengan learning rate 0.1, model mencapai akurasi train sebesar 92.8%, dan akurasi validate serta test masing-masing 90.2% dan 88.5%, menunjukkan kinerja yang baik meskipun ada sedikit penurunan pada data uji. Pada learning rate 0.01, model menunjukkan kinerja terbaik dengan akurasi train 93.0%, akurasi validate 90.8%, dan akurasi test 89.1%, memberikan hasil yang stabil dan optimal pada semua data, dengan kemampuan generalisasi yang sangat baik. Sedangkan dengan learning rate 0.001, meskipun akurasi train tetap tinggi (91.9%), akurasi validate dan test menurun menjadi 89.4% dan 87.3%, menunjukkan bahwa learning rate yang lebih rendah memperlambat proses pelatihan dan sedikit mengurangi kemampuan model untuk menggeneralisasi. Dapat disimpulkan, learning rate 0.01 direkomendasikan untuk model VGG16 dalam tugas klasifikasi aksara Kaganga, dengan batch size 64 dengan hasil per epoch seperti pada **Gambar 2**.



Gambar 2. Akurasi VGG16 LR 0.01 dan BS 64

Plot ini menunjukkan akurasi model seiring bertambahnya epoch pada dataset pelatihan dan validasi. Akurasi pelatihan (garis biru) menunjukkan peningkatan yang cepat dan stabil, mencapai nilai sekitar 0.93 di akhir, yang menandakan model belajar dengan baik pada data pelatihan. Sebaliknya, akurasi validasi (garis oranye) mulai lebih rendah dan berfluktuasi signifikan pada epoch-epoch awal, meskipun akhirnya stabil di sekitar 0.89. Fluktuasi ini menunjukkan bahwa model belum sepenuhnya dapat menggeneralisasi pada data validasi, mengindikasikan adanya potensi *overfitting*. Jarak antara akurasi pelatihan dan validasi ini semakin lebar, yang menandakan *overfitting* pada model. Pengaruh pengaturan *hyperparameter*, terutama *batch size* dan *learning rate*, sangat penting dalam hal ini. Kombinasi *batch size* 64 dengan *learning rate* 0.01 memberikan hasil terbaik, dengan akurasi tertinggi pada data uji, meskipun sedikit penurunan pada validasi. Pengaturan *batch size* yang lebih besar dan *learning rate* yang lebih moderat terbukti dapat meningkatkan kinerja model, namun tetap perlu memperhatikan keseimbangan antara pelatihan dan validasi untuk mencegah *overfitting*.

4. Kesimpulan

Berdasarkan hasil eksperimen yang dilakukan pada VGG16 dengan berbagai kombinasi *batch size* dan *learning rate* untuk klasifikasi citra aksara Kaganga, dapat disimpulkan bahwa pengaturan *hyperparameter* yang tepat memiliki pengaruh signifikan terhadap kinerja model. Secara umum, *batch size* 32 dengan *learning rate* 0.01 memberikan hasil yang paling optimal, dengan akurasi terbaik pada data train, validate, dan test. Pada *batch size* 16, meskipun model memberikan hasil yang cukup baik dengan *learning rate* 0.01, nilai akurasi pada data test lebih rendah dibandingkan dengan *batch size* 32 dan 64, mengindikasikan bahwa *batch size* yang lebih kecil cenderung lebih cepat mengalami *overfitting*. Sementara itu, pada *batch size* 64, *learning rate* 0.01 juga memberikan hasil terbaik dengan akurasi test yang mencapai 89.1%, menunjukkan bahwa *batch size* yang lebih besar dapat meningkatkan kinerja model pada data uji, meskipun ada sedikit penurunan pada akurasi validasi. Sebaliknya, *learning rate* 0.001 cenderung memberikan pelatihan yang lebih lambat dan hasil yang kurang optimal pada data test. Dapat disimpulkan, *learning rate* 0.01 adalah direkomendasikan untuk model VGG16 dalam tugas klasifikasi aksara Kaganga, terutama ketika digunakan dengan *batch size* 32 atau 64.

5. Ucapan Terima Kasih

Terima kasih kepada Bapak Erwin Dwika Putra yang telah menyediakan dataset penelitian ini, serta Universitas Sjakhyakirti yang telah mendukung dan memberikan fasilitas yang diperlukan dalam penelitian ini. Dukungan dan kontribusi dari kedua pihak tersebut sangat berharga bagi kelancaran dan keberhasilan penelitian ini.

6. Daftar Pustaka

- [1] V. Ayumi, "Pengenalan Objek Bunga Berbasis Deep Learning Menggunakan Model Resnet50 dan MobileNet-v2," *JSAI (Journal Sci. Appl. Informatics)*, vol. 5, no. 3, pp. 188–193, 2022.
- [2] D. Fitriyah, K. M. Suryaningrum, N. T. M. Sagala, V. Ayumi, and S. M. Lim, "Fine-Tuned MobileNetV2 and VGG16 Algorithm for Fish Image Classification," in *2022 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, IEEE, 2022, pp. 384–389.
- [3] I. Nurhaida, R. A. M. Zen, V. Ayumi, and H. Wei, "Determining the Number of Batik Motif Object based on Hierarchical Symmetry Detection Approach," *Indones. J. Electr. Eng. Informatics*, vol. 9, no. 1, pp. 141–152, 2021.
- [4] S. Rahayu, S. Sandiwarno, E. D. Putra, M. Utami, and H. Setiawan, "Model Sequential Resnet50 Untuk Pengenalan Tulisan Tangan Aksara Arab," *JSAI (Journal Sci. Appl. Informatics)*, vol. 6, no. 2, pp. 234–241, 2023.
- [5] 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.
- [6] 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.
- [7] H. Noprisson, "Perbandingan Algoritma Xception dan VGG16 Untuk Pengenalan Lebah Pollen-Bearing," *JSAI (Journal Sci. Appl. Informatics)*, vol. 5, no. 3, pp. 223–227, 2022.
- [8] H. Noprisson, "Fine-Tuning Model Transfer Learning VGG16 Untuk Klasifikasi Citra Penyakit Tanaman Padi," *JSAI (Journal Sci. Appl. Informatics)*, vol. 5, no. 3, pp. 244–249, 2022.
- [9] E. P. Purwandari, D. Andreswar, and S. Sarwono, "Mobile Kaganga Language as Cultural Literacy and Learning Media for Elementary Schools," *Ilkog. Online*, vol. 20, no. 1, 2021.
- [10] 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.
- [11] H. Kono, Y. Sakamoto, Y. Ji, and H. Fujii, "Automatic Transfer Rate Adjustment for Transfer Reinforcement Learning," *Int. J. Artif. Intell. Appl.*, vol. 11, no. 6, pp. 47–54, 2020, doi: 10.5121/IJAIA.2020.11605.
- [12] F. A. Torghabeh, Y. Modaresnia, and M. M. Khalilzadeh, "Effectiveness of learning rate in dementia severity prediction using VGG16," *Biomed. Eng. Appl. Basis Commun.*, vol. 35, no. 03, p. 2350006, 2023.
- [13] D. Granzio, S. Zohren, and S. Roberts, "Learning rates as a function of batch size: A random matrix theory approach to neural network training," *J. Mach. Learn. Res.*, vol. 23, no. 173, pp. 1–65, 2022.
- [14] I. A. Usmani, M. T. Qadri, R. Zia, F. S. Alrayes, O. Saidani, and K. Dashtipour, "Interactive effect of learning rate and batch size to implement transfer learning for brain tumor classification," *Electronics*, vol. 12, no. 4, p. 964, 2023.
- [15] K. Prasanna, S. R. K. Raju, and J. Krishna, "Effect of learning rate on the performance of VGG-16 for prediction of cardiomegaly in chest X-ray images," in *Recent Advances in Material, Manufacturing, and Machine Learning*, CRC Press, 2024, pp. 836–844.

7. Penulis



Mariana Purba adalah dosen di Fakultas Ilmu Komputer, Universitas Sjakhyakirti, dengan keahlian di bidang deep learning dan informatika. Beliau menyelesaikan pendidikan S3 dalam bidang Ilmu Teknik di Universitas Sriwijaya (UNSRI). Minat penelitian beliau pada penerapan teknologi *deep learning* dan pengembangan sistem cerdas.