

PENERAPAN DEEP LEARNING UNTUK PENGENALAN CITRA TULISAN TANGAN AKSARA LAMPUNG

Putri Dianing Ratri¹, Dwi Yana Ayu Andini², Ratnasari³, Dwi Feriyanto⁴

^{1,2,3,4}Program Studi Teknik Informatika Fakultas Teknologi dan Informatika Universitas Aisyah Pringsewu

Info Artikel

Riwayat Artikel:

Received April 29, 2025
Revised May 09, 2025
Accepted May 28, 2025

Corresponding Author:

Dwi Yana Ayu Andini
Email:
dwi yana@aisyahuniversity.ac.id



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

Abstract – In the field of artificial intelligence, technology has opened new opportunities for preserving cultural heritage, including the Lampung script. One method that shows great potential in script recognition is Deep Learning. This research aims to develop a handwritten image recognition model for the Lampung script using deep learning methods with the ResNet-50 architecture and transfer learning. Handwritten data of the Lampung script were collected from various sources and processed through image normalization and augmentation to improve the quality of the training data. The model was built using the ResNet-50 architecture with transfer learning, which allows the use of pre-trained models to enhance efficiency. The research results show that the model is capable of classifying 20 primary characters of the Lampung script with adequate performance. However, the study suggests further data collection and exploration of augmentation techniques to improve results. This research not only aims to enhance the recognition of the Lampung script but also contributes to efforts to preserve and introduce the Lampung script to the wider public through modern technology.

Keywords: Deep Learning, CNN, Lampung Script

Abstrak – Dalam bidang kecerdasan buatan, teknologi telah membuka peluang baru untuk melestarikan warisan budaya, termasuk aksara Lampung. Salah satu metode yang menunjukkan potensi besar dalam pengenalan aksara adalah Deep Learning. Penelitian ini bertujuan mengembangkan model pengenalan citra tulisan tangan aksara Lampung menggunakan metode deep learning dengan arsitektur ResNet-50 dan transfer learning. Data tulisan tangan aksara Lampung dikumpulkan dari berbagai sumber dan diproses melalui normalisasi serta augmentasi gambar untuk meningkatkan kualitas data pelatihan. Model yang dibangun menggunakan arsitektur ResNet-50 dengan transfer learning, yang memungkinkan pemanfaatan model yang sudah dilatih sebelumnya untuk meningkatkan efisiensi. Hasil penelitian menunjukkan bahwa model ini mampu mengklasifikasikan 20 induk huruf aksara Lampung dengan tingkat performa yang memadai. Meski demikian, penelitian ini masih menyarankan pengumpulan data tambahan dan eksplorasi teknik augmentasi untuk meningkatkan hasil lebih lanjut. Penelitian ini tidak hanya bertujuan meningkatkan pengenalan aksara Lampung, tetapi juga berkontribusi terhadap upaya pelestarian dan pengenalan aksara Lampung kepada masyarakat luas melalui teknologi modern.

Kata Kunci: Deep Learning, CNN, Aksara Lampung

I. PENDAHULUAN

Indonesia mempunyai budaya yang sangat beragam, diantaranya kesenian, tatanan bahasa sampai dengan tingkah laku masyarakatnya. Aksara Lampung disebut juga dengan istilah Kaganga, merupakan aksara asli Lampung dengan teknik penulisan yang membacanya diawali kiri kemudian ke kanan dengan huruf induk sejumlah 20 huruf [1]. Sebagai negara yang kaya akan keberagaman budaya, tidak hanya berupaya menjaga tradisi secara konvensional, tetapi juga mengadopsi teknologi modern untuk melestarikan warisan budaya. Dalam konteks ini, perkembangan teknologi, khususnya dalam bidang kecerdasan buatan, telah memberikan peluang baru untuk mempertahankan warisan budaya khususnya aksara Lampung. Salah satu metode yang menunjukkan potensi besar adalah Deep Learning, suatu cabang dari kecerdasan buatan yang memanfaatkan algoritma neural network yang kompleks untuk memahami dan memproses data.

Penelitian sebelumnya yang telah mengeksplorasi penggunaan teknologi Optical Character Recognition (OCR) dan Convolutional Neural Network (CNN) untuk pengenalan aksara Lampung. Salah satu penelitian sebelumnya, yang mencoba menggunakan arsitektur MobileNet V2, menarik perhatian dengan mencoba mengklasifikasikan aksara Lampung dari sejumlah penulis yang berbeda. Meskipun upaya ini telah melibatkan pengumpulan data yang cukup besar, dengan 53.764 gambar aksara Lampung dari 100 penulis, hasilnya menunjukkan bahwa tingkat akurasi pada tahap pelatihan sebesar 0.57 dan pada tahap validasi sebesar 0.32. Lebih lanjut, precision dan recall pada data validasi juga tercatat rendah, menandakan bahwa masih ada tantangan yang perlu diatasi dalam konteks pengenalan aksara Lampung menggunakan pendekatan ini [2]. Keterbatasan hasil yang ditemui pada


penelitian sebelumnya, terutama terkait dengan tingkat akurasi yang rendah pada tahap pelatihan dan validasi, memberikan landasan yang kuat untuk menjelajahi pendekatan baru. Salah satu inovasi yang dapat diadopsi adalah penerapan teknik transfer learning, yang telah terbukti efektif dalam memperbaiki performa model pada tugas-tugas pengenalan citra.

Dalam konteks pengenalan citra, transfer learning telah terbukti menjadi pendekatan yang efektif dalam memperbaiki kinerja model pengenalan citra di berbagai bidang. Integrasi transfer learning dalam penelitian pengenalan aksara Lampung menjadi strategi yang menarik dan berpotensi signifikan dalam meningkatkan akurasi dan klasifikasi citra aksara Lampung. Oleh karena itu, penelitian ini bertujuan untuk mengisi kekosongan yang terdapat dalam penelitian sebelumnya dengan menerapkan transfer learning pada arsitektur CNN dalam konteks pengenalan aksara Lampung.

II. METODE

a. Tahapan Penelitian

Tahapan penelitian ini dilakukan secara terencana dan sistematis untuk mencapai tujuan dari penelitian ini. Tahapan penelitian dapat diamati dalam bentuk diagram pada Gambar 2.1.



Gambar 2. 1 Tahapan Penelitian [8]

Berdasarkan Gambar 2.1, terlihat bahwa terdapat 11 langkah dalam penelitian ini, mulai dari penentuan topik hingga proses interpretasi hasil. Berikut ini adalah penjelasan dari masing-masing langkah:

1. Studi Literatur

Pada tahap ini, peneliti melakukan studi Pustaka yang berkaitan dengan penelitian. Dalam hal ini, studi Pustaka meliputi bahasa dan aksara Lampung, rekognisi tulisan tangan, *Deep Learning*, *Convolutional Neural Network (CNN)*, dan *ResNet-50*.

2. Pengumpulan Data

Data yang digunakan dalam penelitian ini terdiri dari kumpulan gambar tulisan tangan aksara Lampung yang terdiri dari huruf ka-ga-nga-pa-ba-ma-ta-na-ca-ja-nya- ya-a-la-ra-sawa-ha-gha. Pengumpulan data dilakukan dengan cara mengambil gambar menggunakan kamera *smartphone* dan menyimpannya dalam format JPG. Gambar- gambar tersebut nantinya akan dipotong atau diubah ukurannya menjadi ukuran 224x224. Selain itu, pelabelan dilakukan pada setiap aksara Lampung tulisan tangan yang terdiri dari 20 kelas. Sebelum memasuki tahap pelabelan data, gambar yang telah dipotong akan diperbesar dengan menggunakan beberapa teknik, antara lain *rescaling*, rotasi, pergeseran lebar, pergeseran tinggi, penyesuaian kecerahan, dan pembalikan horizontal. Setelah melakukan augmentasi gambar, data akan dilabeli dengan membaginya menjadi data *training* dan data testing.

3. Persiapan Data

Persiapan data merupakan tahap yang krusial dalam pengembangan model pembelajaran mesin, khususnya untuk pengenalan gambar. Proses ini melibatkan tindakan-tindakan untuk memverifikasi bahwa data yang akan digunakan oleh model memiliki format yang tepat, telah diubah ukurannya dengan benar, dan telah disiapkan untuk keperluan pelatihan dan pengujian. Pada penelitian pengenalan tulisan tangan aksara

Lampung, persiapan data meliputi manipulasi citra, augmentasi, normalisasi, dan pembagian data ke dalam set pelatihan dan pengujian.

4. Pemodelan Algoritma

Pada pemodelan algoritma merupakan tahap perancangan CNN adalah tahap dimana model dibangun untuk digunakan dalam proses pelatihan data. Proses pembelajaran *Convolutional Neural Networks (CNN)* diawali dengan inisialisasi parameter dan iterasi sesuai dengan jumlah maksimum iterasi yang ditentukan. Model CNN yang digunakan adalah model ResNet-50 yang telah dilatih sebelumnya.


5. Evaluasi Model

Setelah pembangunan model *Deep Learning*, tahap selanjutnya adalah melakukan pengujian untuk mengukur kinerja model dalam pengenalan citra tulisan tangan aksara Lampung menggunakan data pengujian.

III. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini terdiri dari gambar tulisan tangan aksara Lampung, dengan 20 kelas karakter yang berbeda. Data diperoleh dengan memotret tulisan tangan aksara Lampung menggunakan kamera smartphone, lalu diolah ke dalam format JPG seperti pada Gambar 3.1.




Gambar 4. 1 Data Aksara Awal

3.2 Persiapan Data

Tahap persiapan data merupakan langkah penting untuk memastikan data yang digunakan dalam pelatihan dan pengujian model berada dalam kondisi optimal. Proses persiapan data dimulai dengan pengubahan ukuran gambar aksara Lampung menjadi 224x224 piksel agar sesuai dengan input yang diperlukan oleh model ResNet-50. Selain itu, dilakukan preprocessing data yang mencakup beberapa langkah: normalisasi piksel gambar untuk memastikan nilai berada dalam rentang 0 hingga 1, sehingga memudahkan model dalam konvergensi; konversi gambar ke skala abu-abu untuk mengurangi kompleksitas fitur warna; serta penghilangan noise atau artefak yang mungkin ada pada gambar. Setelah itu, teknik augmentasi seperti rescaling, rotasi, pergeseran lebar, pergeseran tinggi, penyesuaian kecerahan, dan pembalikan horizontal diterapkan untuk meningkatkan variasi data.

3.2.1 Manipulasi Data Citra

Gambar-gambar tulisan tangan aksara Lampung yang telah dikumpulkan dari berbagai sumber dipotong dan diubah ukurannya menjadi resolusi 224x224 piksel. Resolusi ini dipilih karena sesuai dengan dimensi input yang diperlukan oleh arsitektur model ResNet-50. Pemotongan gambar dilakukan untuk memastikan bahwa hanya bagian yang relevan dari gambar (yaitu karakter aksara Lampung) yang diproses, sementara resizing dilakukan untuk menyamakan ukuran seluruh gambar sehingga dapat diolah dengan konsisten oleh model. Visualisasi *cropping* dapat dilihat pada Gambar 4.2.




Gambar 4.2 Proses Pemotongan Data Menjadi 224 x 224 Piksel

3.2.2 Augmentasi

Untuk meningkatkan variasi data dan memperkaya dataset, gambar-gambar yang sudah dimanipulasi kemudian diaugmentasi menggunakan berbagai teknik. Berikut adalah hasil dari proses augmentasi:

1) Rotasi


Rotasi melibatkan pemutaran gambar ke arah tertentu dengan sudut tertentu. Dalam augmentasi ini, gambar diputar secara acak hingga maksimal 40 derajat ke kiri atau ke kanan. Visualisasi rotasi dapat dilihat pada Gambar 4.3.



Gambar 4. 3 Visualisasi Proses Rotasi

2) Pergeseran Lebar dan Tinggi (*Width and Height Shift*)

Pergeseran lebar dan tinggi adalah teknik augmentasi yang menggeser posisi gambar secara horizontal (lebar) atau vertikal (tinggi) dengan persentase tertentu dari total ukuran gambar. Dalam kasus ini, gambar dapat digeser hingga 20% dari lebar atau tingginya. Visualisasi dapat dilihat pada Gambar 4.4.



Gambar 4. 4 Visualisasi Proses Penyesuaian Kecerahan

3.2.3 Pemodelan

Pada tahap ini, model Convolutional Neural Network (CNN) dengan arsitektur ResNet-50 yang telah dilatih sebelumnya diimplementasikan. Arsitektur ResNet-50 dipilih karena kemampuannya dalam menangani masalah klasifikasi gambar, termasuk pengenalan tulisan tangan, serta efisiensinya dalam belajar dari gambar berukuran besar. Model ResNet-50 yang sudah dilatih pada dataset ImageNet dimuat tanpa lapisan fully connected (`include_top=False`), yang memungkinkan penambahan lapisan kustom untuk pengenalan Aksara Lampung. Ini berarti, lapisan klasifikasi standar ImageNet tidak disertakan sehingga model dapat disesuaikan untuk mengklasifikasikan 20 huruf induk Aksara Lampung. Konfigurasi parameter untuk pemodelan dapat dilihat pada Tabel 4.1.

Tabel 4. 1 Konfigurasi Parameter

Parameter	Deskripsi
Model	ResNet-50
Weights	imagenet

Include Top	False
Input Shape	(224, 224, 3)
Base Model Output	Feature maps from the last convolutional layer of ResNet-50 (excluding top layers)
GlobalAveragePooling2D	Reduces the spatial dimensions of feature maps to a single value per feature channel
Dense Layer 1	64 units, activation function: ReLU
Dense Layer 2	num_classes units (equal to the number of output classes), activation function: softmax
Trainable Layers	Layers from Dense layers only (base model layers are frozen)
Optimizer	Adam with learning rate 0.001

Parameter	Deskripsi
Loss Function	categorical_crossentropy
Metrics	accuracy
Batch Size	20
Epochs	200

Berdasarkan Tabel 4.4, model ResNet-50 yang telah dilatih sebelumnya pada dataset *ImageNet* dimuat tanpa lapisan *fully connected (top layers)*. `include_top=False` berarti kita tidak menyertakan lapisan terakhir yang digunakan untuk klasifikasi pada dataset *ImageNet*, memungkinkan kita untuk menambahkan lapisan klasifikasi sesuai dengan kebutuhan dataset aksara Lampung. Lapisan-lapisan tambahan ditambahkan di atas model dasar *GlobalAveragePooling2D* untuk Mengurangi dimensi spasial output dari model dasar, mengubahnya menjadi satu vektor fitur per gambar. `Dense(64, activation='relu')` yang berarti lapisan *dense* dengan 64 unit dan fungsi aktivasi ReLU untuk menangkap hubungan non-linear dalam data. `Dense(num_classes, activation='softmax')` berarti Lapisan output dengan jumlah unit sama dengan jumlah kelas (`num_classes`) dan fungsi aktivasi *softmax* untuk klasifikasi multi-kelas. Model akhir dibangun dengan menggunakan input dari model dasar (`base_model.input`) dan output dari lapisan tambahan yang baru ditambahkan (`predictions`). Kemudian, lapisan-lapisan dari model dasar dibekukan agar tidak dilatih ulang selama pelatihan. Ini memastikan bahwa fitur dasar yang sudah dipelajari dari dataset *ImageNet* tetap utuh, dan hanya lapisan-lapisan baru yang akan dioptimalkan.

Model dikompilasi menggunakan *Optimizer Adam* dengan *learning rate* 0.001 untuk pembaruan bobot yang efisien. *Loss Function Categorical Crossentropy*, karena ini adalah masalah klasifikasi multi-kelas. *Metrics* Akurasi untuk mengevaluasi performa model selama pelatihan dan pengujian. Ukuran batch mengatur berapa banyak gambar yang diproses model dalam satu iterasi pembelajaran. Dalam hal ini, model menggunakan 20 gambar per batch. Jumlah iterasi penuh adalah 200 di mana seluruh dataset digunakan untuk pelatihan model.

3.2.4 Hasil Pelatihan Model


Pelatihan model dilakukan selama 200 epoch dengan menggunakan arsitektur ResNet-50 yang telah dilatih sebelumnya, diadaptasi dengan lapisan tambahan untuk tugas pengenalan aksara Lampung. Proses pelatihan menunjukkan kemajuan yang signifikan dalam hal akurasi dan loss, baik pada data pelatihan maupun validasi. Berikut adalah hasil pelatihan model pada epoch- epoch tertentu, yang merangkum performa model pada awal pelatihan, perkembangan di tengah, dan hasil akhir pelatihan yang bisa dilihat pada Tabel 4.2.

Tabel 4. 2
Ringkasan Hasil Pelatihan Model

Epoch	Akurasi Pelatihan	Loss Pelatihan	Akurasi Validasi	Loss Validasi
1	0.0604	3.0196	0.0850	2.9704
10	0.2633	2.4760	0.2475	2.4969
20	0.3465	2.1259	0.3275	2.1734
30	0.4169	1.8940	0.3600	2.0140
40	0.4616	1.7431	0.4300	1.7696
50	0.5058	1.5952	0.4675	1.6413
60	0.5446	1.4759	0.4700	1.6021

70	0.5828	1.3665	0.5475	1.4541
80	0.6078	1.2907	0.5625	1.3813
90	0.6261	1.2162	0.6100	1.2824
100	0.6308	1.1777	0.6000	1.2680
110	0.6755	1.0814	0.6375	1.1960
120	0.6707	1.0731	0.6375	1.1674
130	0.6874	1.0175	0.6575	1.1364
140	0.7038	0.9609	0.6625	1.0582
150	0.7126	0.9396	0.7000	1.0414
160	0.7295	0.9042	0.6900	1.0051
170	0.7252	0.8757	0.6625	1.0291
180	0.7424	0.8313	0.6850	1.0174
190	0.7472	0.8185	0.7100	0.9924
200	0.7532	0.7864	0.7000	0.9692

Berdasarkan Tabel 4.3, pada epoch pertama, model menunjukkan akurasi yang sangat rendah baik pada data pelatihan maupun data validasi, yaitu masing-masing 6.04% dan 8.50%. Loss pada epoch ini juga relatif tinggi, yaitu 3.0196 untuk pelatihan dan 2.9704 untuk validasi. Hal ini diharapkan karena model baru mulai belajar dan belum mengalami pelatihan yang cukup. Seiring berjalannya waktu, pada epoch ke-10, model menunjukkan perbaikan dengan akurasi pelatihan meningkat menjadi 26.33% dan akurasi validasi menjadi 24.75%. Loss juga mengalami penurunan, dengan nilai loss pelatihan menjadi 2.4760 dan loss validasi menjadi 2.4969. Perkembangan yang lebih signifikan terjadi pada epoch ke-20, di mana akurasi pelatihan mencapai 34.65% dan akurasi validasi mencapai 32.75%, dengan loss pelatihan sebesar 2.1259 dan loss validasi sebesar 2.1734. Memasuki epoch ke-100, model menunjukkan hasil yang lebih memuaskan dengan akurasi pelatihan mencapai 63.08% dan akurasi validasi sebesar 60.00%. Loss juga mengalami penurunan yang signifikan, dengan nilai loss pelatihan 1.1777 dan loss validasi 1.2680. Pada akhir pelatihan di epoch ke-200, model mencapai akurasi pelatihan terbaik sebesar 75.32% dan akurasi validasi 70.00%. Loss akhir pada epoch ini adalah 0.7864 untuk pelatihan dan 0.9692 untuk validasi. Grafik proses pelatihan dapat dilihat pada Gambar 4.5.



Gambar 4. 5 Grafik Proses Pelatihan Model

3.2.5 Evaluasi Model

Setelah proses pelatihan model selesai, tahap selanjutnya adalah melakukan evaluasi model untuk mengukur kinerjanya dalam mengenali tulisan tangan aksara Lampung. Evaluasi ini dilakukan dengan menggunakan data pengujian yang tidak terlihat selama proses pelatihan. Evaluasi dilakukan dengan menggunakan confusion matrix untuk menganalisis kesalahan klasifikasi secara lebih mendetail, yaitu melihat huruf-huruf mana yang sering salah diklasifikasikan. Metrik-metrik kinerja yang digunakan dalam evaluasi ini meliputi akurasi, presisi, recall, dan F1-score.

Tabel 4. 4


Metrik Kinerja Model Pada Data Uji untuk Setiap Kelas

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
a	0.53	0.80	0.64

ba	0.90	0.45	0.60
ca	0.70	0.95	0.81
da	0.80	0.80	0.80
ga	0.69	1.00	0.82
gha	0.88	0.75	0.81
ha	0.88	0.75	0.81
ja	0.57	0.80	0.67
ka	0.56	0.70	0.62
la	0.40	0.20	0.27
ma	0.73	0.40	0.52
na	0.81	0.65	0.72
nga	0.56	0.75	0.64
nya	0.67	0.70	0.68
pa	0.92	0.55	0.69
ra	0.88	0.75	0.81
sa	0.47	0.45	0.46
ta	0.55	0.80	0.65
wa	0.56	0.45	0.50
ya	0.89	0.85	0.87
Accuracy	-	-	0.68
Macro Avg	0.70	0.68	0.67

Hasil evaluasi menunjukkan bahwa model ResNet-50 yang telah diadaptasi dengan teknik transfer learning mencapai akurasi yang sangat tinggi, yaitu sebesar 68% pada data pengujian. Hal ini menunjukkan bahwa model berhasil mengenali aksara Lampung dengan tingkat akurasi yang cukup baik diatas 50%. Selain itu, metrik kinerja lainnya juga menunjukkan hasil yang memuaskan. Nilai rata-rata presisi model adalah 70%, yang mengindikasikan seberapa baik model dalam mengidentifikasi kelas-kelas yang benar dari semua prediksi positif yang dihasilkannya. Rata-rata recall model mencapai 68%, yang menunjukkan seberapa baik model dalam menemukan semua instance dari kelas-kelas yang relevan. F1-score, yang merupakan rata-rata harmonis dari presisi dan recall, menunjukkan keseimbangan yang baik antara presisi dan recall.

Untuk memberikan gambaran yang lebih detail tentang performa model dalam mengklasifikasikan setiap kelas aksara, matriks kebingungan disajikan pada Gambar 4.6. Matriks ini memvisualisasikan jumlah prediksi yang benar dan salah untuk setiap kelas aksara, serta membantu dalam menganalisis area di mana model mungkin perlu diperbaiki atau ditingkatkan.



Gambar 4. 6 Confusion Matrix Model

Secara keseluruhan, hasil evaluasi ini menunjukkan bahwa model yang dikembangkan memiliki kinerja yang cukup baik dalam tugas pengenalan aksara Lampung, dengan kemampuan yang solid untuk mengklasifikasikan setiap karakter dengan akurasi yang tinggi dan keseimbangan yang baik antara presisi dan recall.

IV. SIMPULAN

Penelitian ini bertujuan untuk mengembangkan model pengenalan tulisan tangan aksara Lampung dengan menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur ResNet-50. Berdasarkan hasil penelitian dan evaluasi model, berikut adalah kesimpulan yang dapat diambil:

1. Klasifikasi 20 Induk Huruf Aksara Lampung: Model CNN dengan arsitektur ResNet-50 yang diadaptasi melalui transfer learning mampu mengklasifikasikan 20 induk huruf aksara Lampung dengan akurasi sebesar 68%. Hal ini menunjukkan bahwa model dapat mengenali dan membedakan karakter aksara Lampung masih diperlukan pengembangan lebih lanjut untuk meningkatkan tingkat ketepatannya.
2. Kontribusi Terhadap Pelestarian Aksara Lampung: Selain menawarkan solusi teknis untuk pengenalan aksara Lampung, penelitian ini juga berpotensi mendukung pelestarian aksara Lampung. Dengan menggunakan teknologi deep learning, model ini dapat diimplementasikan dalam aplikasi digital yang membantu memperkenalkan dan mengajarkan aksara Lampung kepada masyarakat luas. Hal ini mendukung upaya pelestarian warisan budaya Lampung melalui media pembelajaran berbasis teknologi.

UCAPAN TERIMAKASIH

Penelitian ini dapat dilaksanakan dengan baik berkat bantuan dari beberapa pihak, untuk itu peneliti mengucapkan terimakasih telah diberikan kesempatan dan kerjasama yang baik dalam penelitian ini.

DAFTAR PUSTAKA

- [1] A. Junaidi, S. Trianingsih, and M. Iqbal, "Writer Identification of Lampung Handwritten Documents Based on Selected Characters," 2020.
- [2] "JEPIN (Jurnal Edukasi dan Penelitian Informatika) Penerapan Convolutional Neural Network (CNN) pada Pengenalan Aksara Lampung Berbasis Optical Character Recognition (OCR) Agus Mulyanto #1, Erlina Susanti #2, Farli Rosi #3, Wajiran #4, Rohmat Indra Borman #5", [Online]. Available: <https://colab.research.google.com>.
- [3] A. Maharil, "PERBANDINGAN ARSITEKTUR VGG16 DAN RESNET50 UNTUK REKOGNISI TULISAN TANGAN AKSARA LAMPUNG," *Jurnal Informatika dan Rekayasa Perangkat Lunak (JATIKA)*, vol. 3, no. 2, pp. 236–243, 2022, [Online]. Available: <http://jim.teknokrat.ac.id/index.php/informatika>
- [4] P. Bintoro and A. Harjoko, "Lampung Script Recognition Using Convolutional Neural Network," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 16, no. 1, p. 23, Jan. 2022, doi: 10.22146/ijccs.70041.
- [5] M. S. A. Bin Rosli, I. S. Isa, S. A. Ramlan, S. N. Sulaiman, and M. I. F. Maruzuki, "Development of CNN Transfer Learning for Dyslexia Handwriting Recognition," in *Proceedings - 2021 11th IEEE International Conference on Control System, Computing and Engineering, ICCSCE 2021*, Institute of Electrical and Electronics Engineers Inc., Aug. 2021, pp. 194–199. doi: 10.1109/ICCSCE52189.2021.9530971.
- [6] M. Farid Naufal, J. Siswanto, and M. Ghifari Kusuma Wicaksono, "Klasifikasi Tulisan Tangan Pada Resep Obat Menggunakan Convolutional Neural Network."
- [7] A. Muh. A. Siddik, "Comparison of Transfer Learning Algorithm Performance in Hand Sign Language Digits Image Classification," *Jurnal Matematika, Statistika dan Komputasi*, vol. 20, no. 1, pp. 75–89, Sep. 2023, doi: 10.20956/j.v20i1.26503.
- [8] S. Rahayu, S. Sandiwarno, E. D. Putra, M. Utami, and H. Setiawan, "Model Sequential Resnet50 Untuk Pengenalan Tulisan Tangan Aksara Arab Article Info ABSTRAK," *JSAI: Journal Scientific and Applied Informatics*, vol. 06, no. 02, 2023, doi: 10.36085.
- [9] Y. Brianorman and R. Munir, "Perbandingan Pre-Trained CNN: Klasifikasi Pengenalan Bahasa Isyarat Huruf Hijaiyah," *J. Sistem Info. Bisnis*, vol. 13, no. 1, pp. 52–59, Jul. 2023, doi: 10.21456/vol13iss1pp52-59.
- [10] Chikkamagaluru. D. of C. S. and E. Adichunchanagiri Institute of Technology, Institute of Electrical and Electronics Engineers. Bangalore Section, and Institute of Electrical and Electronics Engineers, *ICAIT - 2019 : First IEEE International Conference on Advances in Information Technology : proceedings : 24th - 27th July 2019*.
- [11] S. Chatterjee, R. K. Dutta, D. Ganguly, K. Chatterjee, and S. Roy, "Bengali Handwritten Character Classification using Transfer Learning on Deep Convolutional Neural Network," Feb. 2019, [Online]. Available: <http://arxiv.org/abs/1902.11133>
- [12] I. H. Sarker, "Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions," 2021, doi: 10.20944/preprints202108.0060.v1.
- [13] J. M. Johnson and T. M. Khoshgoftaar, "Survey on deep learning with class imbalance," *J Big Data*, vol. 6, no. 1, Dec. 2019, doi: 10.1186/s40537-019-0192-5.
- [14] X. Ni, "Frontiers in Business, Economics and Management Research on Image Recognition Technology Based on Machine Learning," 2022.
- [15] R. Blank *et al.*, "DEVELOPMENTAL MEDICINE & CHILD NEUROLOGY EACD RECOMMENDATIONS International clinical practice recommendations on the definition, diagnosis, assessment, intervention, and

- psychosocial aspects of developmental coordination disorder,” 2019, doi: 10.1111/dmcn.14132#support- information-section.
- [16] M. A. Saleem, N. Senan, F. Wahid, M. Aamir, A. Samad, and M. Khan, “Comparative Analysis of Recent Architecture of Convolutional Neural Network,” *Math Probl Eng*, vol. 2022, 2022, doi: 10.1155/2022/7313612.
- [17] Z. Kayumov, D. Tumakov, and S. Mosin, “Hierarchical Convolutional Neural Network for Handwritten Digits Recognition,” in *Procedia Computer Science*, Elsevier B.V., 2020, pp. 1927–1934. doi: 10.1016/j.procs.2020.04.206.
- [18] C. Y. Lee, P. Gallagher, and Z. Tu, “Generalizing Pooling Functions in CNNs: Mixed, Gated, and Tree,” *IEEE Trans Pattern Anal Mach Intell*, vol. 40, no. 4, pp. 863–875, Apr. 2018, doi: 10.1109/TPAMI.2017.2703082.
- [19] Purwono, A. Ma’arif, W. Rahmانيar, H. I. K. Fathurrahman, A. Z. K. Frisky, and Q. M. U. Haq, “Understanding of Convolutional Neural Network (CNN): A Review,” *International Journal of Robotics and Control Systems*, vol. 2, no. 4, pp. 739–748, 2022, doi: 10.31763/ijrcs.v2i4.888.
- [20] A. Sreenivas, “Indian Sign Language Communicator Using Convolutional Neural Network.” [Online]. Available: <https://www.researchgate.net/figure/The-26-letters- and-10-digits-of-American-Sign-Language->
- [21] K. I. K. Wang, X. Zhou, W. Liang, Z. Yan, and J. She, “Federated Transfer Learning Based Cross-Domain Prediction for Smart Manufacturing,” *IEEE Trans Industr Inform*, vol. 18, no. 6, pp. 4088–4096, Jun. 2022, doi: 10.1109/TII.2021.3088057.
- [22] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, Dec. 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.
- [23] F. A. Alsalmán1, S. F. Khorshid, and A. B. Sallow, “Disease Diagnosis Systems Using Machine Learning and Deep learning Techniques Based on TensorFlow Toolkit: A review.” [Online]. Available: www.csmj.mosuljournals.com
- [24] V. Khoromskaia and B. N. Khoromskij, “Reduced Higher Order SVD: ubiquitous rank- reduction method in tensor-based scientific computing,” Jan. 2022, [Online]. Available: <http://arxiv.org/abs/2201.12663>.