ISSN: 3063-556X

# Identifikasi citra aksara Lota Ende menggunakan transfer learning MobileNetV2

**Natalia Vanessa Sailo*, Kartono Pinaryanto**
Universitas Sanata Dharma, Yogyakarta
*vanessasailo772@gmail.com

**Volume:** 4

**Tahun:** 2026

**Halaman:** 1–11

**DOI:**
https://doi.org/10.24071/usdb.v4.559

This work is licensed under a Creative Commons Attribution 4.0 International License.

**Abstrak:** Disrupsi kecerdasan buatan (AI) membuka peluang bagi perguruan tinggi untuk berperan aktif dalam melestarikan budaya lokal melalui inovasi akademik berbasis teknologi. Aksara Lota, salah satu warisan budaya masyarakat Ende, kini semakin jarang digunakan sehingga berisiko punah. Sebagai kontribusi riset dan pengabdian akademik, penelitian ini bertujuan mengembangkan serta mengevaluasi kinerja sistem identifikasi citra aksara Lota menggunakan metode *Transfer Learning* dengan arsitektur MobileNetV2. Penelitian menggunakan metode *Research and Development* (R&D) dengan *dataset* 480 citra huruf aksara Lota hasil digitalisasi buku dan tulisan tangan responden, yang melalui tahap *preprocessing* dan augmentasi sebelum pelatihan model. Kombinasi parameter terbaik diperoleh menggunakan *optimizer* Adam, batch size 16, epoch 15, dan learning rate 0,001, menghasilkan *validation accuracy* sebesar 97,22%. Pengujian pada data testing memperoleh *accuracy* 96%, *precision* 97%, *recall* 96%, dan *F1-score* 96%. Hasil *User Acceptance Testing* menunjukkan nilai rata-rata 4,60 dari skala 5, mengindikasikan penerimaan pengguna yang baik terhadap sistem. Temuan ini membuktikan bahwa MobileNetV2 efektif mengidentifikasi citra aksara Lota, sekaligus menjadi contoh konkret bagaimana inovasi AI di lingkungan akademik dapat mendukung digitalisasi dan pelestarian budaya lokal di tengah disrupsi teknologi pendidikan tinggi.

**Kata kunci:** aksara Lota, identifikasi citra, inovasi akademik, MobileNetV2, *transfer learning*

## PENDAHULUAN

Disrupsi kecerdasan buatan (AI) yang berlangsung cepat pada dekade terakhir membuka peluang baru bagi perguruan tinggi untuk berperan lebih aktif dalam pelestarian budaya lokal melalui inovasi akademik berbasis teknologi. Salah satu warisan budaya yang menghadapi ancaman kepunahan adalah aksara Lota, sistem tulisan tradisional masyarakat Ende, Nusa Tenggara Timur, yang pada masa lampau digunakan dalam pencatatan hukum adat, penulisan naskah keagamaan lokal, penyampaian pesan antarkelompok masyarakat, hingga dokumentasi cerita rakyat.

Secara historis, aksara Lota merupakan turunan dari aksara Bugis yang mulai berkembang di Ende sekitar abad ke-16 pada masa pemerintahan Raja Goa XIV, I Mangngarangi Daeng Manrabia yang bergelar Sultan Alauddin (1593–1639) (Aryanto et al., 2023). Aksara ini pada mulanya dituliskan pada media daun lontar (*wunu koli*) menggunakan alat sederhana, sebelum penggunaan kertas dikenal secara luas di Nusantara, dan mengalami adaptasi bentuk sesuai kebutuhan komunikasi masyarakat Ende sehingga menjadi identitas budaya tersendiri.

Perkembangan modernisasi membawa perubahan besar terhadap pola komunikasi masyarakat. Dominasi aksara Latin dalam sektor pendidikan, administrasi, dan kehidupan sehari-hari

menyebabkan penggunaan aksara Lota semakin berkurang dan hanya sebagian kecil masyarakat, terutama kalangan tua adat, yang masih mampu membaca serta memahaminya (Oktora, 2010a). Kondisi budaya tulis yang semakin terasing di tengah masyarakatnya sendiri juga dilaporkan oleh Oktora (2010b), yang mencatat minimnya dokumentasi digital serta terbatasnya upaya pelestarian yang sistematis. Aksara Lota dapat dikategorikan sebagai endangered script yang berpotensi hilang apabila tidak dilakukan upaya revitalisasi, termasuk melalui digitalisasi 30 huruf dasarnya yang selama ini terdokumentasi pada aplikasi referensi Aksara Ende (Somad Tech, 2023).

Seiring berkembangnya ilmu informatika, teknologi pengolahan citra dan *deep learning* menawarkan solusi modern untuk pelestarian aksara tradisional. Sejak diperkenalkannya arsitektur Convolutional Neural Network (CNN) untuk pengenalan dokumen dan karakter tulisan tangan (LeCun et al., 1998), CNN terbukti mampu mengenali pola visual kompleks, termasuk variasi tulisan tangan, perbedaan pencahayaan, dan bentuk aksara yang beragam. Penerapan CNN dengan arsitektur MobileNetV2 (Sandler et al., 2018) pada klasifikasi tulisan aksara Jawa menunjukkan akurasi hingga 87,41%, sehingga menegaskan potensi arsitektur ini dalam mendukung digitalisasi aksara tradisional di Indonesia (Arief et al., 2024). Pendekatan Transfer Learning yang memanfaatkan model pra-latih (pre-trained model) juga banyak digunakan untuk meningkatkan performa deep learning pada kondisi data pelatihan yang terbatas, karena model dapat memanfaatkan pengetahuan yang telah dipelajari dari dataset berskala besar seperti ImageNet (Deng et al., 2009) sehingga mempercepat konvergensi dan meningkatkan akurasi (Nurlaela et al., 2025; Zhuang et al., 2021).

Berdasarkan penelusuran literatur, hingga saat ini belum ditemukan penelitian yang secara khusus mengembangkan sistem identifikasi citra aksara Lota menggunakan Transfer Learning maupun arsitektur deep learning lain, sehingga terdapat kekosongan penelitian (*research gap*) yang signifikan dalam bidang digitalisasi aksara lokal di Nusa Tenggara Timur. Ketiadaan sistem identifikasi otomatis, tingginya risiko kepunahan, serta minimnya dokumentasi digital menjadi alasan kuat mengapa penelitian ini dilakukan.

Oleh karena itu, penelitian ini bertujuan mengembangkan sistem identifikasi citra aksara Lota menggunakan metode Transfer Learning dengan arsitektur MobileNetV2 serta mengevaluasi kinerja model yang dihasilkan, baik dari sisi metrik teknis maupun tingkat penerimaan pengguna. Penelitian ini diharapkan tidak hanya berkontribusi pada pengembangan teknologi pengenalan citra, tetapi juga menjadi contoh konkret peran perguruan tinggi dalam merespons disrupsi AI melalui inovasi akademik yang mendukung digitalisasi dan pelestarian budaya lokal.

**Kajian pustaka dan penelitian terdahulu**

Penelitian mengenai penerapan Transfer Learning pada objek visual bermuatan budaya turut dilakukan oleh peneliti Universitas Udayana yang membandingkan arsitektur InceptionV3 dan MobileNetV2 dalam klasifikasi citra topeng Bali. Hasil penelitian menunjukkan bahwa MobileNetV2 mampu memberikan performa klasifikasi yang kompetitif dengan jumlah parameter yang jauh lebih ringan dibandingkan InceptionV3, sehingga lebih efisien untuk dataset terbatas dan aplikasi dengan keterbatasan sumber daya komputasi (Yuniaria et al., 2024). Meskipun objek yang diklasifikasikan bukan aksara, temuan ini relevan karena membuktikan efektivitas MobileNetV2 dalam mengenali pola visual budaya yang memiliki tingkat kerumitan tinggi.

Pada ranah pelestarian aksara daerah, Rismayanti et al. (2025) mengembangkan aplikasi pembelajaran aksara Lontara Bugis berbasis Android untuk siswa sekolah dasar dan menemukan bahwa pemanfaatan teknologi digital efektif meningkatkan motivasi serta pemahaman siswa terhadap aksara daerah. Penelitian Rahmawati et al. (2021) menerapkan CNN untuk pengenalan aksara Sunda dan memperoleh akurasi yang baik meski menggunakan arsitektur CNN konvensional tanpa Transfer Learning, sementara Sianturi (2026) mengembangkan sistem klasifikasi aksara Batak Toba lengkap tulisan tangan, termasuk tanda diakritiknya, menggunakan Transfer Learning berbasis EfficientNet-B0 dan memperoleh akurasi hingga 99% pada data pengujian, yang menegaskan efektivitas pendekatan Transfer Learning untuk digitalisasi aksara daerah secara umum.

Penelitian pengenalan tulisan tangan (*handwritten character recognition*) berbasis CNN juga dilakukan oleh Ameng (2025), yang berhasil mengonversi tulisan tangan alfabet menjadi teks digital dengan akurasi 89%. Pada sisi lain, Firmansyah et al. (2025) menunjukkan bahwa Transfer Learning tetap mampu memberikan performa sangat baik meskipun hanya menggunakan dataset berukuran relatif kecil (500 citra) pada klasifikasi penyakit daun tebu, dengan salah satu model pra-latih mencapai akurasi hingga 100%. Temuan tersebut memperkuat alasan pemilihan Transfer Learning pada penelitian ini, mengingat keterbatasan jumlah dataset aksara Lota yang tersedia.

Berdasarkan uraian penelitian terdahulu, metode CNN dan Transfer Learning terbukti efektif dalam pengenalan aksara lokal maupun objek visual budaya lainnya. Namun demikian, penelitian yang secara khusus membahas identifikasi citra aksara Lota dari Ende menggunakan arsitektur MobileNetV2 masih sangat minim, sehingga penelitian ini memiliki nilai kebaruan (*novelty*) yang tinggi. Berdasarkan latar belakang dan kajian pustaka tersebut, rumusan masalah penelitian ini adalah: (1) bagaimana mengembangkan sistem identifikasi citra aksara Lota berbasis deep learning menggunakan Transfer Learning dengan arsitektur MobileNetV2; (2) seberapa tinggi tingkat akurasi model yang dihasilkan; dan (3) bagaimana tingkat penerimaan pengguna (*user acceptance*) terhadap sistem yang dikembangkan.

## METODE

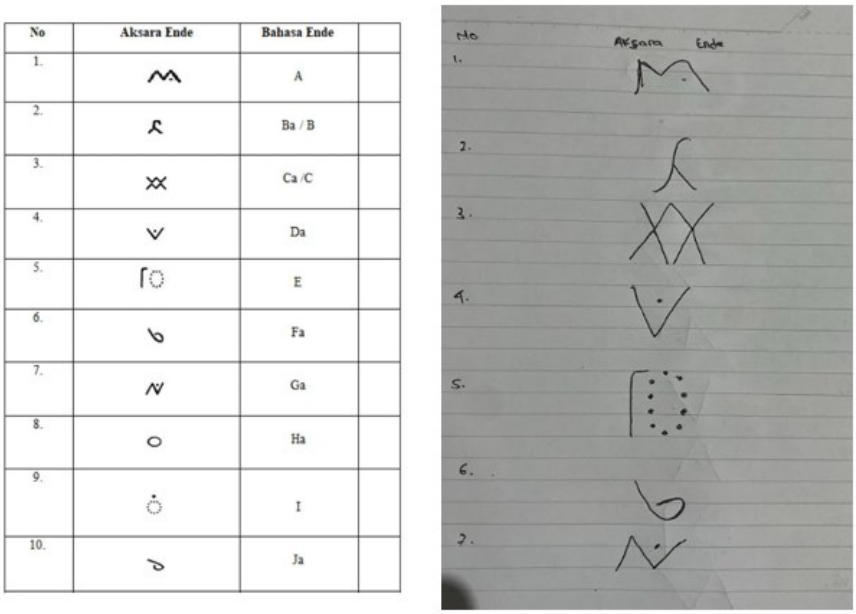
### Desain penelitian

Penelitian ini menggunakan metode Research and Development (R&D) dengan pendekatan pengembangan sistem identifikasi berbasis komputer, mengadaptasi kerangka ADDIE (*Analysis, Design, Development, Implementation, Evaluation*) yang disesuaikan dengan tujuan dan ruang lingkup penelitian. Tahap *Analysis* mengidentifikasi permasalahan minimnya dokumentasi digital dan belum tersedianya sistem identifikasi otomatis aksara Lota. Tahap *Design* mencakup perancangan arsitektur sistem, alur preprocessing dan augmentasi, struktur model deep learning, serta antarmuka aplikasi web sederhana. Tahap *Development* meliputi pengumpulan dataset, implementasi preprocessing dan augmentasi, pembangunan model MobileNetV2 berbasis Transfer Learning, serta pengembangan aplikasi web menggunakan framework Flask sebagai antarmuka pengujian. Tahap *Implementation* mengintegrasikan model hasil pelatihan ke dalam aplikasi web agar dapat menerima input citra dan menampilkan hasil identifikasi secara otomatis, sedangkan tahap *Evaluation* mengukur kinerja sistem melalui metrik teknis dan User Acceptance Testing (UAT).

### Dataset dan etika penelitian

Dataset penelitian terdiri dari 480 citra huruf aksara Lota yang mencakup 30 kelas huruf dasar, dikumpulkan dari dua sumber. Sumber pertama adalah digitalisasi buku aplikasi Aksara Ende karya Maria Matildis Banda (Somad Tech, 2023), yang menghasilkan satu citra referensi per huruf melalui proses tangkapan layar, pemotongan (*cropping*) manual, dan pelabelan. Sumber kedua adalah tulisan tangan 15 responden yang mengisi Google Form berisi instruksi penulisan 30 huruf dasar aksara Lota, sehingga setiap huruf memperoleh 15 citra tambahan dan total 16 citra per kelas (480 citra untuk 30 kelas). Variasi dataset mencakup perbedaan gaya tulisan, ketebalan tinta, pencahayaan, kemiringan tulisan, serta warna dan tekstur kertas. Gambar 1 menunjukkan contoh sumber data sebelum melalui tahap cropping dan pelabelan. Seluruh partisipan yang memberikan sampel tulisan tangan maupun yang terlibat dalam pengujian penerimaan pengguna (UAT) telah memberikan persetujuan (*informed consent*) secara sukarela setelah memperoleh informasi yang memadai mengenai tujuan penggunaan data sebelum berpartisipasi dalam penelitian ini. Identitas responden bersifat opsional dan tidak digunakan dalam proses pelatihan maupun pengujian model, sehingga data yang dimanfaatkan tetap anonim dan hanya digunakan untuk kepentingan akademik. Dataset dibagi menggunakan metode *stratified split* menjadi 80% data training (360 citra), 10% data validation (45 citra), dan 10% data testing (45 citra), sehingga proporsi tiap kelas huruf tetap seimbang pada seluruh subset. Augmentasi citra

hanya diterapkan pada *data training*, sedangkan data validation dan testing tidak diaugmentasi agar evaluasi performa model tetap objektif dan merepresentasikan kondisi data nyata.



| No | Aksara Ende | Bahasa Ende | |
|---|---|---|---|
| 1. | | A | |
| 2. | | Ba / B | |
| 3. | | Ca /C | |
| 4. | | Da | |
| 5. | | E | |
| 6. | | Fa | |
| 7. | | Ga | |
| 8. | | Ha | |
| 9. | | I | |
| 10. | | Ja | |

(a) (b)

Gambar 1. Contoh sumber data: (a) cuplikan halaman referensi Aksara Ende yang didigitalisasi; (b) contoh lembar tulisan tangan responden sebelum cropping

**Preprocessing dan augmentasi citra**

Tahap preprocessing menyeragamkan format citra agar sesuai dengan kebutuhan input MobileNetV2, meliputi konversi citra ke format RGB, perubahan ukuran citra menjadi 224×224 piksel, dan normalisasi nilai piksel dari rentang 0–255 menjadi 0–1 melalui parameter rescale = 1/255 pada ImageDataGenerator. Selanjutnya, augmentasi citra diterapkan untuk memperkaya variasi data latih tanpa mengubah identitas kelasnya, mengacu pada teknik-teknik yang telah terbukti efektif mengatasi keterbatasan data pada tugas visi komputer (Shorten & Khoshgoftaar, 2019), meliputi rotasi ±20°, *horizontal flip*, zoom dengan rentang 0,8–1,2, dan penyesuaian tingkat kecerahan (*brightness*) dengan rentang 0,7–1,3. Contoh hasil penerapan tiap teknik augmentasi pada citra aksara Lota ditunjukkan pada Gambar 2. Kombinasi teknik augmentasi ini bertujuan meningkatkan kemampuan generalisasi model terhadap variasi tulisan tangan, pencahayaan, dan orientasi citra yang mungkin dijumpai pada kondisi penggunaan nyata.

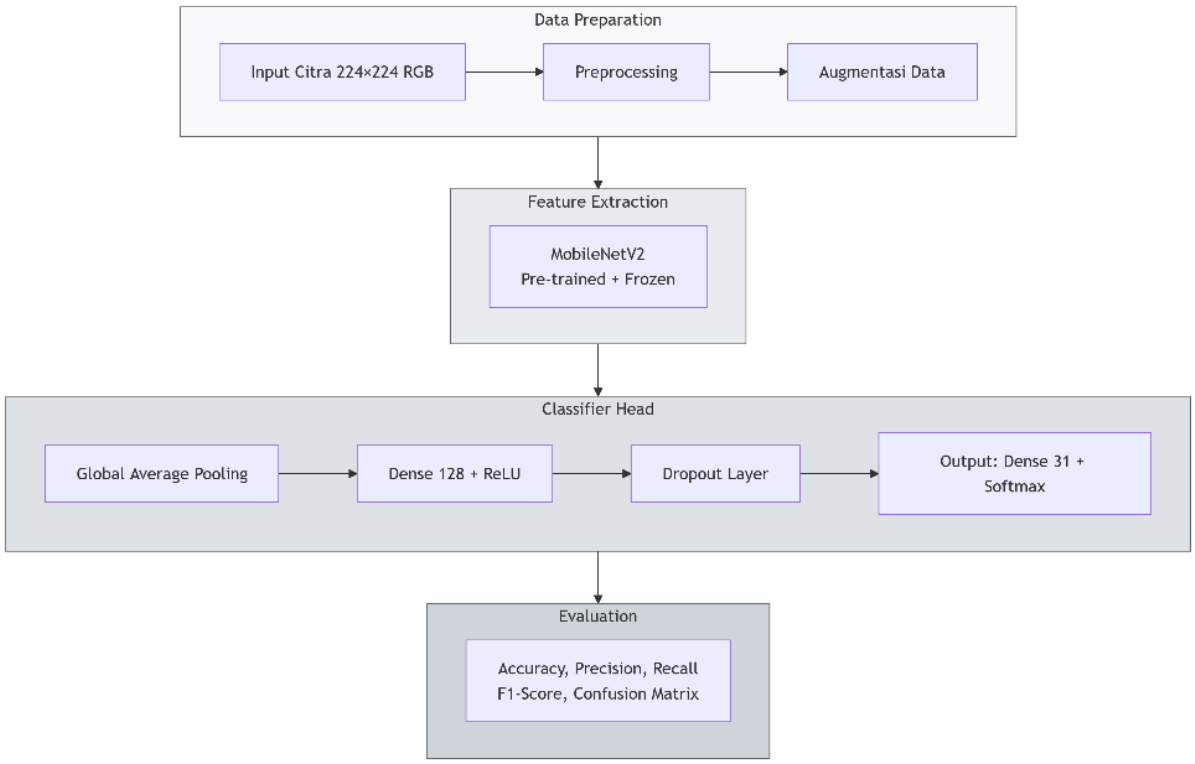



Gambar 2. Contoh hasil augmentasi citra aksara Lota untuk setiap teknik yang diterapkan

**Arsitektur model dan skema pelatihan**

Model yang digunakan adalah MobileNetV2 (Sandler et al., 2018) dengan pendekatan Transfer Learning, di mana bobot pretrained ImageNet (Deng et al., 2009) dimanfaatkan sebagai ekstraktor fitur dan seluruh layer dasar (*base model*) dibekukan (*frozen*) untuk mencegah *overfitting* akibat keterbatasan dataset. Pada bagian akhir model, ditambahkan *Global Average Pooling Layer* untuk mereduksi dimensi *feature map*, dilanjutkan dengan *Fully Connected Layer* (*Dense*) berisi 128 neuron

dan fungsi aktivasi ReLU, Dropout Layer dengan nilai 0,5 untuk mengurangi risiko overfitting (Srivastava et al., 2014), serta Output Layer berupa *dense layer* dengan fungsi aktivasi *softmax* yang menghasilkan probabilitas untuk 30 kelas huruf aksara Lota. Alur arsitektur model disajikan pada Gambar 3.




Gambar 3. Diagram alur arsitektur model MobileNetV2 berbasis Transfer Learning

Proses pelatihan model dilakukan melalui eksperimen dengan beberapa variasi parameter yang mengacu pada penelitian sebelumnya, meliputi optimizer (Adam (Kingma & Ba, 2015), RMSprop, dan *Stochastic Gradient Descent*/SGD), learning rate (0,001; 0,0001; dan 0,00001) yang mengacu pada praktik yang digunakan Firmansyah et al. (2025), batch size (16 dan 32) serta jumlah *epoch* (5, 10, dan 15) yang mengacu pada Ramadhan dan Riwurohi (2024). *Loss function* yang digunakan adalah *Categorical Cross-Entropy* karena label data direpresentasikan dalam bentuk *one-hot encoding* untuk klasifikasi multi-kelas. Selama pelatihan, diterapkan *callback* EarlyStopping, ModelCheckpoint, dan ReduceLROnPlateau untuk menghentikan training pada kondisi optimal serta menyimpan model dengan performa validasi terbaik.

**Evaluasi sistem**

Evaluasi teknis dilakukan menggunakan data testing untuk mengukur *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*, guna mengetahui kemampuan model dalam mengklasifikasikan citra aksara Lota secara tepat dan konsisten pada tiap kelas huruf. Selain evaluasi teknis, penelitian ini juga melakukan evaluasi penerimaan pengguna terhadap aplikasi web yang dikembangkan. Evaluasi dilakukan dengan meminta 5 responden mencoba sistem melalui antarmuka *Graphical User Interface* (GUI), kemudian mengisi kuesioner dengan skala Likert 1–5 pada empat aspek: kemudahan penggunaan sistem, kemudahan memahami tampilan antarmuka, kecepatan proses identifikasi, dan kesesuaian hasil prediksi dengan citra yang diinputkan. Sebagai validasi tambahan, hasil identifikasi sistem juga dibandingkan dengan dokumentasi bentuk huruf aksara Lota beserta padanannya yang diberikan oleh penyusun aplikasi referensi Aksara Ende, Ibu Maria Matildis Banda, untuk memastikan konsistensi hasil prediksi terhadap acuan yang benar.

## HASIL DAN PEMBAHASAN

### Hasil

Eksperimen dilakukan terhadap 54 kombinasi parameter yang berasal dari kombinasi 3 optimizer, yaitu Adam, RMSprop, dan Stochastic Gradient Descent (SGD); 2 variasi *batch size*, yaitu 16 dan 32; 3 variasi epoch, yaitu 5, 10, dan 15; serta 3 variasi *learning rate*, yaitu 0,001, 0,0001, dan 0,00001. Kombinasi tersebut diuji untuk menentukan konfigurasi parameter terbaik berdasarkan akurasi validasi (*validation accuracy*) yang dihasilkan pada tiap kombinasi. Ringkasan performa terbaik pada tiap optimizer disajikan pada Tabel 1.

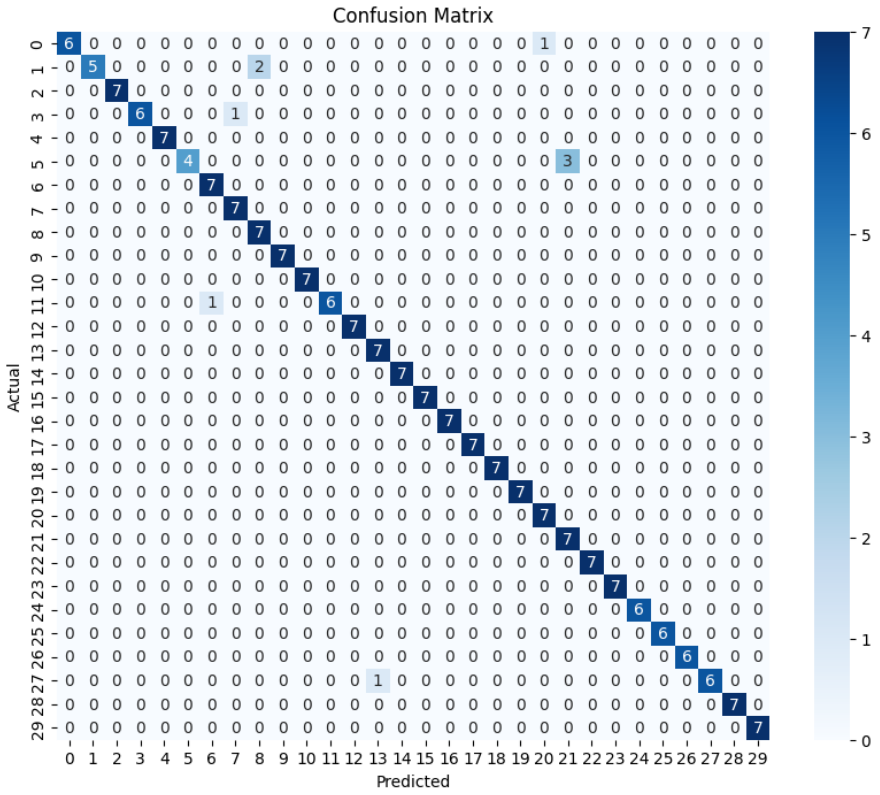
Tabel 1. Ringkasan akurasi validasi terbaik pada tiap optimizer

| Optimizer | Batch size | Epoch | Learning rate | Akurasi validasi |
|---|---|---|---|---|
| Adam | 16 | 15 | 0,001 | 0,9722 |
| RMSprop | 32 | 15 | 0,001 | 0,9556 |
| SGD | 16 | 15 | 0,001 | 0,4778 |

Optimizer Adam secara konsisten menghasilkan performa terbaik dan paling stabil dibandingkan dengan RMSprop dan SGD pada seluruh kombinasi batch size dan epoch yang diuji. Learning rate 0,001 juga secara konsisten menghasilkan akurasi lebih tinggi dibandingkan dengan 0,0001 dan 0,00001 pada ketiga optimizer; sebagai contoh, pada Adam dengan batch size 16 dan epoch 15, akurasi menurun dari 0,9722 pada learning rate 0,001 menjadi 0,8667 pada 0,0001 dan 0,3889 pada 0,00001. Peningkatan jumlah epoch dari 5 ke 15 juga cenderung meningkatkan akurasi pada optimizer Adam dan RMSprop, sementara SGD menunjukkan performa paling rendah pada hampir seluruh kombinasi parameter yang diuji.

Berdasarkan hasil eksperimen, kombinasi parameter terbaik yang dipilih untuk pelatihan model akhir adalah optimizer Adam, batch size 16, epoch 15, dan learning rate 0,001, dengan akurasi validasi sebesar 97,22%. Grafik training menunjukkan peningkatan accuracy dan penurunan loss yang stabil pada data training maupun validation tanpa selisih yang besar di antara keduanya, mengindikasikan bahwa model tidak mengalami overfitting yang signifikan berkat kombinasi preprocessing, augmentasi citra, dan pendekatan Transfer Learning yang diterapkan.

Model dengan parameter terbaik selanjutnya dievaluasi menggunakan data testing. Gambar 4 menunjukkan confusion matrix hasil evaluasi. Confusion matrix menunjukkan dominasi nilai pada diagonal utama matriks, yang menandakan kesesuaian tinggi antara kelas aktual dan kelas hasil prediksi model pada mayoritas kelas huruf. Meskipun demikian, masih terdapat beberapa kesalahan klasifikasi pada kelas-kelas yang memiliki kemiripan bentuk visual, terutama pada huruf-huruf dengan pola lengkungan sederhana.




Gambar 4. Confusion matrix hasil evaluasi model pada data testing

Model MobileNetV2 memperoleh accuracy sebesar 96% pada data testing, dengan macro average precision 0,97, recall 0,96, dan F1-score 0,96. Sebagian besar kelas huruf, seperti *ca*, *dha*, *ha*, *i*, *ka*, *ma*, *mba*, *na*, *nda*, *nga*, *ngga*, *pa*, *ra*, *sa*, *ta*, *u*, *ya*, dan *za*, memperoleh precision, recall, dan F1-score sempurna sebesar 1,00. Namun demikian, beberapa kelas menunjukkan recall lebih rendah, seperti huruf *e* (recall 0,57; F1-score 0,73) dan huruf ba (recall 0,71; F1-score 0,83), yang mengindikasikan model mengalami kesulitan membedakan huruf-huruf dengan kemiripan pola visual tertentu, khususnya kekeliruan yang mengarah pada kelas o.

Tabel 2. Ringkasan hasil evaluasi model pada data testing

| Metrik | Precision | Recall | F1-score | Support |
|---|---|---|---|---|
| Accuracy | – | – | 0,96 | 207 |
| Macro average | 0,97 | 0,96 | 0,96 | 207 |
| Weighted average | 0,97 | 0,96 | 0,96 | 207 |

Selain evaluasi teknis, User Acceptance Testing (UAT) dilakukan terhadap 5 responden yang menjajal aplikasi web identifikasi aksara Lota. Hasil UAT dirangkum pada Tabel 3. Nilai rata-rata keseluruhan UAT sebesar 4,60 dari skala maksimum 5 menunjukkan bahwa sistem dapat diterima dengan baik oleh pengguna. Aspek kemudahan penggunaan dan kemudahan memahami antarmuka memperoleh skor tertinggi (4,80), sedangkan aspek kecepatan proses identifikasi memperoleh skor sedikit lebih rendah (4,20). Sebagai validasi tambahan, hasil identifikasi sistem juga dibandingkan dengan dokumentasi acuan aksara Lota. Dari enam citra uji yang dibandingkan dengan dokumentasi acuan, empat citra teridentifikasi sesuai, sedangkan dua citra keliru diklasifikasikan ke kelas *o*, konsisten dengan pola kesalahan yang teramati pada evaluasi metrik precision dan recall.

Tabel 3. Hasil User Acceptance Testing

| Aspek yang dinilai | Rata-rata skor |
|---|---|
| Kemudahan penggunaan sistem | 4,80 |
| Kemudahan memahami tampilan antarmuka | 4,80 |
| Kecepatan proses identifikasi | 4,20 |
| Kesesuaian hasil prediksi dengan citra yang diinputkan | 4,60 |
| Rata-rata keseluruhan | 4,60 |

**Pembahasan**

Superioritas optimizer Adam dibandingkan RMSprop dan SGD pada penelitian ini sejalan dengan temuan Ramadhan dan Riwurohi (2024), yang menyatakan bahwa pemilihan optimizer, batch size, dan epoch yang tepat sangat memengaruhi kestabilan dan kecepatan konvergensi model CNN. Sifat adaptif Adam (Kingma & Ba, 2015) dalam menyesuaikan learning rate untuk setiap parameter memungkinkan proses pelatihan konvergen lebih cepat dan stabil dibandingkan SGD yang menggunakan learning rate tetap, sehingga lebih sesuai untuk kondisi dataset aksara Lota yang berjumlah relatif kecil.

Akurasi 96% yang diperoleh pada penelitian ini menegaskan efektivitas Transfer Learning dalam mengatasi keterbatasan jumlah data pelatihan, sebagaimana ditemukan Firmansyah et al. (2025) yang memperoleh akurasi tinggi pada klasifikasi penyakit daun tebu meski hanya menggunakan dataset berukuran kecil, serta konsisten dengan tinjauan komprehensif Zhuang et al. (2021) mengenai manfaat Transfer Learning pada kondisi data terbatas. Perbandingan dengan penelitian identifikasi aksara daerah lain turut memberikan konteks yang berarti: Sianturi (2026) memperoleh akurasi hingga 99% pada klasifikasi aksara Batak Toba menggunakan EfficientNet-B0, Rahmawati et al. (2021) memperoleh akurasi yang baik pada pengenalan aksara Sunda menggunakan CNN konvensional tanpa Transfer Learning, sementara Ameng (2025) memperoleh akurasi 89% pada pengenalan tulisan tangan alfabet berbasis CNN konvensional. Posisi akurasi penelitian ini di antara nilai-nilai tersebut mengindikasikan bahwa MobileNetV2 merupakan pilihan arsitektur yang seimbang antara efisiensi komputasi dan tingkat akurasi, konsisten dengan temuan Yuniaria et al. (2024) yang menunjukkan MobileNetV2 tetap kompetitif meski memiliki parameter jauh lebih ringan dibandingkan arsitektur lain seperti InceptionV3.

Pola kesalahan klasifikasi pada huruf *e* dan *ba* yang cenderung keliru diidentifikasi sebagai huruf *o* mengindikasikan bahwa model masih menghadapi tantangan dalam membedakan huruf-huruf dengan kemiripan pola lengkungan visual yang tinggi. Tantangan serupa turut disinggung Yuniaria et al. (2024) dalam konteks klasifikasi objek budaya bermuatan visual kompleks, sehingga perbaikan pada aspek ini dapat menjadi arah penelitian lanjutan, misalnya melalui penambahan variasi data latih khusus pada kelas-kelas yang rentan keliru, penerapan teknik augmentasi lanjutan (Shorten & Khoshgoftaar, 2019), atau penerapan teknik fine-tuning pada sebagian layer MobileNetV2 yang sebelumnya dibekukan. Dari sisi penerimaan pengguna, skor UAT sebesar 4,60 dari skala 5 menunjukkan bahwa sistem yang dikembangkan tidak hanya unggul secara teknis, tetapi juga mudah digunakan dan diterima oleh penggunanya. Skor yang relatif lebih rendah pada aspek kecepatan proses identifikasi mengindikasikan adanya ruang perbaikan pada sisi optimasi performa aplikasi, misalnya melalui kompresi model atau optimasi inferensi pada sisi server.

Secara keseluruhan, penelitian ini menegaskan bahwa inovasi AI berbasis Transfer Learning dapat menjadi kontribusi nyata perguruan tinggi dalam merespons disrupsi teknologi, khususnya melalui riset dan pengabdian akademik yang berorientasi pada pelestarian budaya lokal. Sistem identifikasi aksara Lota yang dikembangkan berpotensi mendukung upaya digitalisasi, pembelajaran, dan revitalisasi aksara tradisional, sekaligus memperkuat literasi AI di lingkungan akademik sebagai

bagian dari pengembangan diri berkelanjutan (*continuous professional development*) dalam menghadapi era disrupsi kecerdasan buatan di pendidikan tinggi.

Penelitian ini memiliki sejumlah keterbatasan yang perlu menjadi perhatian pada penelitian selanjutnya. Pertama, jumlah dataset yang digunakan masih relatif terbatas, yaitu 480 citra untuk 30 kelas huruf, sehingga penambahan variasi data dari lebih banyak responden dapat meningkatkan generalisasi model. Kedua, sistem yang dikembangkan hanya mengklasifikasikan huruf aksara Lota secara terisolasi (isolated character), belum mencakup pengenalan pada level kata atau kalimat yang tersusun dari rangkaian huruf. Ketiga, jumlah responden pada pengujian UAT masih terbatas pada 5 orang, sehingga hasil evaluasi penerimaan pengguna belum sepenuhnya merepresentasikan populasi pengguna yang lebih luas.

## KESIMPULAN

Penelitian ini menunjukkan bahwa disrupsi kecerdasan buatan (AI) dapat dimanfaatkan oleh perguruan tinggi sebagai peluang nyata untuk berperan aktif dalam melestarikan budaya lokal melalui inovasi akademik berbasis teknologi. Sebagai kontribusi riset dan pengabdian akademik, penelitian ini berhasil mengembangkan sekaligus mengevaluasi kinerja sistem identifikasi citra aksara Lota menggunakan metode Transfer Learning dengan arsitektur MobileNetV2 melalui pendekatan Research and Development (R&D), mulai dari tahap pengumpulan dan digitalisasi dataset, preprocessing dan augmentasi citra, hingga pelatihan dan integrasi model ke dalam aplikasi web. Model yang dihasilkan menunjukkan kinerja klasifikasi yang sangat baik dan konsisten pada pengujian data testing, membuktikan bahwa pendekatan Transfer Learning efektif diterapkan meskipun pada kondisi dataset aksara daerah yang masih terbatas jumlahnya. Selain unggul secara teknis, sistem yang dikembangkan juga memperoleh tingkat penerimaan pengguna yang tinggi berdasarkan hasil User Acceptance Testing, yang menandakan bahwa sistem mudah dipahami dan digunakan oleh penggunanya. Secara keseluruhan, temuan ini menegaskan bahwa MobileNetV2 efektif mengidentifikasi citra aksara Lota, sekaligus menjadi contoh konkret bagaimana inovasi AI di lingkungan akademik dapat mendukung digitalisasi dan pelestarian budaya lokal di tengah disrupsi teknologi pendidikan tinggi. Meskipun demikian, penelitian ini masih memiliki keterbatasan pada cakupan dan variasi dataset, lingkup identifikasi yang terbatas pada huruf tunggal, serta jumlah responden pengujian penerimaan pengguna yang relatif sedikit. Penelitian selanjutnya disarankan untuk memperluas jumlah dan variasi dataset, mengembangkan sistem identifikasi pada level kata atau kalimat, membandingkan performa dengan arsitektur deep learning lain, serta menguji penerimaan pengguna pada populasi yang lebih luas guna mendukung upaya pelestarian dan revitalisasi aksara Lota secara berkelanjutan.

## PERNYATAAN PENGGUNAAN *GENERATIVE AI*

Dalam proses penyusunan naskah ini, penulis menggunakan bantuan model kecerdasan buatan generatif Claude (Anthropic) untuk membantu menyusun ulang, merapikan alur penulisan, menyusun daftar pustaka, dan menyesuaikan format naskah hasil penelitian skripsi ke dalam struktur template artikel seminar. Seluruh data, hasil eksperimen, dan temuan penelitian yang disajikan berasal dari penelitian asli yang telah dilakukan penulis. Penulis telah memeriksa, menyunting, dan bertanggung jawab penuh atas keakuratan seluruh konten akhir yang disajikan dalam naskah ini.

**REFERENSI**


Ameng, A. I. (2025). *Sistem pengenalan tulisan tangan (handwriting recognition) menggunakan convolutional neural network (CNN) dengan Python dan TensorFlow* [Skripsi sarjana, STMIK Widya Cipta Dharma]. Wicida Repository. https://repository.wicida.ac.id/6047/

Arief, N. S., Putra, W. A., & Pratama, D. S. (2024). Implementasi CNN Arsitektur MobileNetV2 untuk klasifikasi tulisan aksara Jawa. *Prosiding Seminar Nasional Teknologi Dan Sains Tahun 2024*, *3*, 298–303. https://doi.org/10.29407/z1cbjw36

Aryanto, R., Rosid, M. A., & Busono, S. (2023). Penerapan deep learning untuk pengenalan tulisan tangan bahasa aksara Lota Ende dengan menggunakan metode convolutional neural networks. *Jurnal Informasi Dan Teknologi*, *5*(1), 258–264. https://jidt.org/jidt/article/view/313/175

Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 248–255. https://doi.org/10.1109/CVPR.2009.5206848

Firmansyah, S., Puspaningrum, E. Y., & Mandyartha, E. P.(2025). Implementasi transfer learning dengan perbandingan nilai learning rate pada klasifikasi citra penyakit daun tebu berbasis web. *JATI (Jurnal Mahasiswa Teknik Informatika)*, *9*(5), 7357–7364. https://doi.org/10.36040/jati.v9i5.14609

Kingma, D. P., & Ba, J. (2015). *Adam: A method for stochastic optimization* [Paper presentation]. 3rd International Conference on Learning Representations, San Diego, CA, United States. https://doi.org/10.48550/arXiv.1412.6980

LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, *86*(11), 2278–2324. https://doi.org/10.1109/5.726791

Nurlaela, L., Suhanda, Y., Sopian, A., Dewi, C. S., & Syahrial, R. (2025). Pengembangan Framework Data Mining Berbasis Deep Neural Network dengan Eksplorasi Teknik Transfer Learning untuk Prediksi dan Klasifikasi Data. *Jurnal Rekayasa Informasi Swadharma (JRIS)*, *5*(1), 132–141. https://doi.org/10.56486/jris.vol5no1.723

Oktora, S. (2010a). *Ahli waris aksara Lota Ende*. Kompas.com. https://megapolitan.kompas.com/read/2010/12/09/14575920/ahli-waris-aksara-lota-ende

Oktora, S. (2010b). Budaya tulis: Aksara Lota Ende terasing di negeri sendiri. Kompas. https://jelajah.kompas.id/jejak-peradaban-ntt/baca/budaya-tulis-aksara-lota-ende-terasing-di-negeri-sendiri/

Rahmawati, S. N., Hidayat, E. W., & Mubarok, H. (2021). Implementasi deep learning pada pengenalan aksara Sunda menggunakan metode convolutional neural network. *INSERT: Information System and Emerging Technology Journal*, *2*(1), 46–58. https://doi.org/10.23887/insert.v2i1.37405

Ramadhan, F. M., & Riwurohi, J. E. (2024). Perbandingan optimizer, batch size dan epoch pada metode convolution neural network. *JSil (Jurnal Sistem Informasi)*, *11*(2), 134–138. https://doi.org/10.30656/jsii.v11i2.9249

Rismayanti, Apriyanto, & Suppa, R. (2025). Aplikasi pembelajaran aksara Lontara Bugis berbasis Android pada SDN 152 Cenning di Desa Salobongko Kecamatan Malangke Barat. *JITET: Jurnal Informatika Dan Teknik Elektro Terapan*, *13*(2), 59–69. https://doi.org/10.23960/jitet.v13i2.6075

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 4510–4520. https://doi.org/10.1109/CVPR.2018.00474

Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, *6*, Article 60. https://doi.org/10.1186/s40537-019-0197-0

Sianturi, F. A. (2026). Klasifikasi aksara Batak Toba lengkap tulisan tangan menggunakan transfer learning EfficientNet B0. *Jurnal Sistem Informasi, Teknik Komputer Dan Teknologi Pendidikan (JUSTIKPEN)*, *5*(2), 288–295. https://doi.org/10.55338/justikpen.v5i2.703

Somad Tech. (2023). *Aksara Ende Flores NTT* (Versi 1.0) [Aplikasi mobile]. Google Play Store. https://play.google.com/store/apps/details?id=com.company.etc.aksaraende

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, *15*(56), 1929–1958. http://jmlr.org/papers/v15/srivastava14a.html

Yuniari, N. P. W., Kumara, I. M. S., Raharja, I. K. A. W., Bhaskara, I. M. A., Darma, I. G. W., & Dana, G. W. P. (2024). Analisis klasifikasi citra karakteristik topeng Bali menggunakan model InceptionV3 dan MobileNetV2. *JELiKU (Jurnal Elektronik Ilmu Komputer Udayana)*, *13*(2), 327–338. https://doi.org/10.24843/JLK.2024.v13.i02.p10

Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., & He, Q. (2021). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, *109*(1), 43–76. https://doi.org/10.1109/JPROC.2020.3004555