

IDENTIFIKASI AKSARA JAWI PADA NASKAH KUNO PADA CITRA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK

Devi Maryuni ^{1,*}, Yuhandri ², Sumijan ³

¹ Program Studi Teknik Informatika; Universitas Putra Indonesia YPTK Padang; JL. Raya Lubuk Begalung Padang - Sumatera Barat, Indonesia, telp : (0751) 776666, 775246, 73000 fax : (0751) 71913; e-mail: devi.09114@gmail.com

^{2,3} Program Studi Teknik Informatika; Universitas Putra Indonesia YPTK Padang; JL. Raya Lubuk Begalung Padang - Sumatera Barat, Indonesia, telp : (0751) 776666, 775246, 73000 fax : (0751) 71913; e-mail: yuhandri.yunus@gmail.com, sumijan@upiptk.ac.id,

* Korespondensi: e-mail: devi.09114@gmail.com

Diterima: 24 Februari 2026; Review: 25 Februari 2026; Disetujui: 27 Februari 2026

Cara sitasi: Maryuni D, Yuhandri Y, Sumijan S. 2026. IDENTIFIKASI AKSARA JAWI PADA NASKAH KUNO PADA CITRA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK. Vol 11(1): 23-34.

Abstrak: Permasalahan pelestarian naskah kuno tidak hanya terkait dengan kondisi fisik naskah yang semakin rapuh, tetapi juga dengan keterbatasan sumber daya manusia dalam memahami isi serta aksara yang digunakan, khususnya aksara Jawi atau Arab Melayu. Rendahnya kemampuan masyarakat dalam membaca dan memahami aksara Jawi menjadi hambatan utama dalam mengakses isi naskah secara luas, sehingga berdampak pada terbatasnya pemanfaatan naskah kuno sebagai sumber pengetahuan dan warisan budaya daerah. Penerapan teknologi informasi seperti metode Convolutional Neural Network (CNN) diharapkan mampu mengidentifikasi huruf aksara Jawi sehingga dapat membantu mengatasi keterbatasan kemampuan membaca aksara tersebut serta mendukung proses digitalisasi naskah kuno berbasis citra. Data penelitian diperoleh dari citra naskah kuno beraksara Jawi yang tersimpan di Dinas Kearsipan dan Perpustakaan Provinsi Sumatera Barat, yang selanjutnya digunakan sebagai dataset pelatihan dan pengujian model CNN. Hasil penelitian menunjukkan bahwa model CNN yang dibangun mampu mencapai nilai akurasi sebesar 82,24% dalam mengidentifikasi huruf aksara Jawi. Berdasarkan nilai akurasi tersebut, dapat disimpulkan bahwa metode CNN cukup efektif dalam mengatasi permasalahan keterbatasan pemahaman aksara Jawi dan mampu mengenali pola huruf pada naskah kuno dengan baik. Berdasarkan hasil penelitian, penggunaan CNN diharapkan dapat berdampak pada pelestarian naskah kuno terutama dalam peningkatan aksesibilitas, pelestarian digital, serta pemanfaatan naskah kuno sebagai warisan budaya dan sumber pengetahuan bagi masyarakat luas.

Kata kunci: CNN, MobilnetV2, Aksara, Jawi, Pelestarian

Abstract: The problem of preserving ancient manuscripts is not only related to the increasingly fragile physical condition of the manuscripts, but also to the limitations of human resources in understanding the content and scripts used, especially the Jawi or Arabic Malay scripts. The low ability of the community to read and understand the Jawi script is the main obstacle in accessing the content of the manuscript widely, thus having an impact on the limited use of ancient manuscripts as a source of knowledge and regional cultural heritage. The application of information technology such as the Convolutional Neural Network (CNN) method is expected to be able to identify Jawi characters so that it can help overcome the limitations of the ability to read the script and support the process of digitizing ancient image-based manuscripts. The research data was obtained from images of ancient manuscripts in the Jawi script stored at the West Sumatra Provincial Archives and Library Service, which was then used as a training and testing dataset for the CNN model. The results of the study showed that the CNN model built was able

to achieve an accuracy value of 82.37% in identifying Jawi characters. Based on this accuracy value, it can be concluded that the CNN method is quite effective in overcoming the problem of limited understanding of the Jawi script and is able to recognize the pattern of letters in ancient manuscripts well. Based on the results of the study, the use of CNN is expected to have an impact on the preservation of ancient manuscripts, especially in increasing accessibility, digital preservation, and the use of ancient manuscripts as cultural heritage and a source of knowledge for the wider community.

Keywords: CNN, MobilnetV2, Script, Jawi, Preservation

1. Pendahuluan

Naskah kuno merupakan salah satu sumber referensi utama dalam memahami transformasi budaya dan ilmu pengetahuan dari masa lampau hingga masa sekarang[1]. Keberadaan naskah kuno menjadi sumber rujukan yang tidak ternilai bagi berbagai bidang kehidupan seperti bidang sejarah yang mengungkapkan perjalanan peradaban, antropologi yang menelaah pola kehidupan dan interaksi masyarakat, filologi yang mempelajari bahasa serta perkembangan teks, hukum adat yang merekam norma dan aturan tradisional, hingga studi agama dan filsafat yang menyingkap sistem kepercayaan dan pemikiran mendasar masyarakat masa lampau [2]. Nilai-nilai yang terkandung didalam naskah kuno menjadikan naskah kuno sebagai media edukatif yang strategis dalam mentransfer etika dan kearifan lokal ke generasi masa kini [3].

Permasalahan yang dihadapi dalam pelestarian naskah kuno saat ini yakni banyaknya naskah kuno yang di ditemukan dalam kondisi fisik rapuh akibat faktor usia, iklim, kerusakan biologis yang disebabkan jamur dan serangga serta kondisi penyimpanan yang tidak ideal[4]. Keterbatasan sumber daya manusia yang ahli dalam bidang filologi maupun konservasi naskah menambah tantangan dalam pelestarian naskah tersebut[5]. Upaya pelestarian naskah kuno juga menghadapi hambatan dari sisi teknologi. Minimnya program digitalisasi yang terstruktur dan berkelanjutan menyebabkan sebagian besar naskah belum terdokumentasi secara digital [6].

Pelestarian naskah kuno juga menghadapi hambatan dari berbagai aspek teknologi. Sejumlah penelitian telah membahas lemahnya pelestarian naskah kuno di Indonesia. Program digitalisasi naskah kuno di Indonesia masih belum berjalan secara optimal dan berkelanjutan. Keterbatasan infrastruktur teknologi, baik perangkat keras seperti pemindai beresolusi tinggi maupun perangkat lunak pendukung seperti sistem pengolahan citra dan pengenalan karakter, menyebabkan banyak naskah belum terdokumentasi dalam bentuk digital[7]. Akibatnya, sebagian besar naskah kuno masih bergantung pada bentuk fisik yang rentan terhadap kerusakan dan kehilangan.

Sejumlah penelitian menemukan bahwa digitalisasi naskah menghadapi hambatan serius berupa keterbatasan anggaran, infrastruktur, dan koordinasi kelembagaan[8]. Penelitian lain menyimpulkan bahwa rendahnya ketersediaan tenaga ahli serta minimnya dukungan teknologi menyebabkan program pelestarian tidak optimal[7]. Penelitian terkait Kasara naskah kuno khususnya aksara Jawi juga menunjukkan bahwa aksara Jawi di Sumatera Barat semakin jarang dipahami oleh masyarakat modern, sehingga koleksi beraksara Jawi yang disimpan di lembaga perpustakaan dan kearsipan belum termanfaatkan secara optimal[9]. Temuan-temuan ini menegaskan urgensi pencarian solusi inovatif dalam pelestarian naskah kuno di Indonesia.

Pemanfaatan teknologi digital dan kecerdasan buatan (Artificial Intelligence) diharapkan bisa menjadi salah satu upaya penting dalam melestarikan, mengalisa dan memahami naskah kuno dengan cara yang lebih efektif dan efisien[10]. Digitalisasi mengubah format fisik naskah menjadi bentuk digital sehingga naskah lebih aman, mudah diakses, dan dapat disebarluaskan secara daring[11]. Pengolahan citra digital pada naskah kuno, seperti analisis bentuk huruf dan tekstur tulisan, dapat dilakukan secara komputasional. Ini membuka peluang untuk menerapkan pendekatan Machine Learning dalam proses identifikasi dan klasifikasi aksara tradisional.

Penerapan Machine Learning (ML) dalam pengolahan citra memungkinkan sistem komputer mempelajari pola dan struktur visual secara mandiri melalui proses pelatihan berbasis data, sehingga mampu mengenali, mengklasifikasikan, dan menafsirkan citra dengan tingkat akurasi yang tinggi[12]. Machine Learning khususnya algoritma Convolutional Neural Network telah terbukti efektif dalam pengenalan pola visual dan pengolahan citra dua dimensi. CNN mampu mengekstraksi fitur secara otomatis tanpa memerlukan rekayasa fitur manual, hal ini cocok digunakan untuk mempelajari karakter dari setiap huruf sehingga dapat melakukan proses identifikasi dan klasifikasi secara otomatis. Terdapat beragam penelitian terkait pemanfaatan

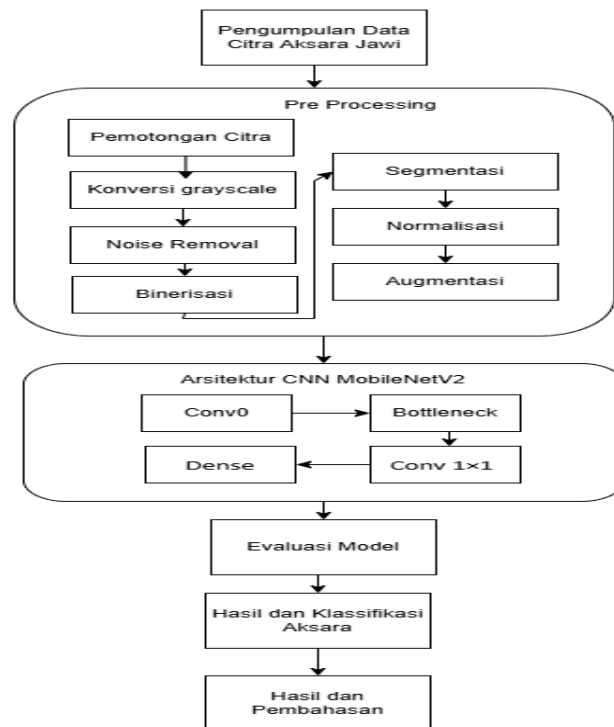
teknologi terkait pengolahan citra digital untuk mengidentifikasi aksara baik itu aksara yang ada di Indonesia maupun yang ada diluar negeri. Penelitian terkait aksara Lampung mendapatkan hasil akurasi yang cukup signifikan yakni diatas 97% untuk pengenalan aksara Lampung[13].

Kejelasan efektivitas pengolahan citra digital dalam pengenalan aksara tradisional di Indonesia sejalan dengan temuan penelitian internasional. Kamal mengembangkan aplikasi "Huruf" yang menggunakan Convolutional Neural Network (CNN) untuk mengenali aksara Arab tulisan tangan, mencapai akurasi 96,93% pada Dataset AHCD dan 99,35% pada Dataset MadBase[14]. Penelitian ini menunjukkan bahwa teknologi Machine Learning dengan metode pengolahan citra digital dapat mengatasi tantangan kompleksitas aksara Arab, seperti bentuk huruf yang bergantung pada posisi dalam kata dan variasi gaya tulisan tangan. Temuan ini sejalan dengan penelitian lain yang mengembangkan model hybrid CNN-BiGRU untuk pengenalan aksara Arab tulisan tangan, mencapai akurasi hingga 97,05%. Pendekatan ini menunjukkan bahwa integrasi model temporal dan representasi kontekstual dapat meningkatkan kinerja pengenalan aksara Arab secara signifikan[15].

Berdasarkan hasil penelitian sebelumnya maka penelitian ini juga akan menggunakan metode Convolutional Neural Network (CNN) untuk melakukan identifikasi aksara jawi. Pengembangan model tersebut dilakukan dengan menggunakan arsitektur MobilenetV2 yang digunakan sebagai model dasar (pre-trained model) dalam proses identifikasi citra aksara Jawi. MobileNetV2 dimanfaatkan tanpa melakukan perubahan pada struktur arsitektur utama, dengan penyesuaian hanya pada lapisan klasifikasi akhir agar sesuai dengan jumlah kelas aksara Jawi yang digunakan. Identifikasi aksara jawi dengan metode Convolutional Neural Network (CNN) diharapkan dapat memberikan kontribusi dalam upaya pelestarian naskah kuno sebagai salah satu warisan budaya lokal, khususnya naskah kuno beraksara Jawi di Provinsi Sumatera Barat. Penelitian ini tidak hanya menawarkan solusi teknis dalam identifikasi aksara, tetapi juga mendukung peningkatan akses masyarakat terhadap warisan intelektual bangsa secara berkelanjutan.

2. Metode Penelitian

Proses identifikasi aksara jawi menggunakan Convolutional Neural Network arsitektur MobilenetV2 dilakukan melalui beberapa percobaan untuk mendapatkan hasil identifikasi yang baik. Proses kerja identifikasi aksara jawi dengan Convolutional Neural Network MobilenetV2 di mulai dari tahapan pengumpulan data citra yang dilanjutkan dengan proses preprocessing untuk menghasilkan citra dengan kualitas yang baik, seragam, dan representatif sebelum digunakan dalam proses pelatihan model dan kemudian dilanjutkan dengan proses identifikasi aksara jawi dengan CNN mobilenetV2. Urutan tahapan proses identifikasi aksara jawi ini divisualisasikan dalam Gambar 1.



Gambar 1. Tahapan proses identifikasi

Berdasarkan tahapan proses identifikasi yang disajikan pada Gambar 1, kerangka penelitian ini diawali dengan tahap pengumpulan citra, yaitu pengambilan data citra Aksara Jawi yang diperoleh dari hasil digitalisasi naskah kuno milik Dinas Kearsipan dan Perpustakaan Provinsi Sumatera Barat. Citra yang telah dikumpulkan selanjutnya melalui tahap preprocessing, yang bertujuan untuk meningkatkan kualitas citra agar sesuai untuk proses pengolahan dan analisis lebih lanjut. Setelah tahap preprocessing, dilakukan perancangan dan pelatihan model Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2 sebagai metode utama dalam proses identifikasi aksara. Model yang telah dilatih kemudian melalui tahap evaluasi kinerja untuk mengukur kemampuan MobileNetV2 dalam melakukan klasifikasi karakter Aksara Jawi. Tahap akhir dari penelitian ini adalah penyajian hasil klasifikasi aksara Jawi beserta pembahasan terhadap performa model yang dihasilkan.

- a. Pengumpulan Data Citra Aksara Jawi

Tahap ini bertujuan memperoleh dataset citra aksara Jawi dari naskah kuno melalui proses digitalisasi daskah kuno milik Dinas Kearsipan dan Perpustakaan Provinsi Sumatera Barat menggunakan scanner atau kamera resolusi tinggi. Setiap citra merepresentasikan satu huruf dan dikelompokkan berdasarkan kelasnya. Keberagaman bentuk tulisan, kondisi tinta, serta degradasi dokumen diperhatikan untuk meningkatkan kemampuan generalisasi model.
- b. Preprocessing

Preprocessing dilakukan untuk meningkatkan kualitas citra dan menyesuaikan data dengan kebutuhan model. Tahapan meliputi pemotongan citra (cropping), konversi grayscale, penghilangan noise, binerisasi, segmentasi karakter, normalisasi ukuran citra (misalnya 224×224 piksel), serta augmentasi data. Proses ini bertujuan menonjolkan fitur huruf dan mengurangi gangguan visual.
- c. Arsitektur CNN MobileNetV2


Model yang digunakan adalah Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2. Arsitektur ini memanfaatkan convolution layer, bottleneck (inverted residual block), dan pointwise convolution (1×1) untuk ekstraksi fitur yang

efisien. Lapisan dense (fully connected) digunakan sebagai tahap klasifikasi akhir untuk menentukan kelas huruf aksara Jawi.

- d. **Evaluasi Model**
Evaluasi dilakukan menggunakan data uji untuk mengukur kinerja model. Metrik yang digunakan meliputi akurasi, precision, recall, dan confusion matrix. Tahap ini bertujuan mengetahui kemampuan model dalam mengenali dan membedakan huruf aksara Jawi secara tepat.
- e. **Hasil dan Klasifikasi Aksara**
Model menghasilkan prediksi berupa label huruf dan nilai kepercayaan (confidence score). Hasil klasifikasi menunjukkan kemampuan sistem dalam mengidentifikasi karakter, termasuk huruf yang memiliki kemiripan bentuk.
- f. **Hasil dan Pembahasan**
Bagian ini membahas performa model berdasarkan hasil evaluasi, termasuk analisis kesalahan klasifikasi dan pengaruh preprocessing terhadap akurasi. Secara umum, penggunaan MobileNetV2 menunjukkan efektivitas dalam mendukung identifikasi aksara Jawi berbasis pengolahan citra digital.

2.1 Dataset Penelitian

Proses identifikasi aksara jawi dengan menggunakan metode Convolutional Neural Network (CNN) arsitektur MobileNetV2 menggunakan dataset citra aksara jawi. Dataset yang digunakan dalam penelitian ini diperoleh dari hasil digitalisasi naskah kuno milik Dinas Kearsipan dan Perpustakaan Provinsi Sumatera Barat. Setiap citra Aksara Jawi berasal dari lembaran dokumen naskah kuno yang ditulis menggunakan tinta hitam pada media kertas dengan tingkat degradasi yang berbeda-beda. Dataset citra Aksara Jawi yang telah dikumpulkan kemudian melalui tahap seleksi dan prapemrosesan, sehingga diperoleh total sebanyak 3.434 citra yang digunakan dalam penelitian ini. Contoh sampel dataset citra Aksara Jawi ditunjukkan pada Gambar 2, yang memperlihatkan variasi bentuk karakter hasil digitalisasi naskah kuno.



Sumber: Dinas Kearsipan dan Perpustakaan Sumatera Barat (2022)
Gambar 2. Sampel Dataset Penelitian

Gambar 2 merupakan sample Dataset penelitian untuk identifikasi aksara jawi. Untuk keperluan pelatihan dan pengujian model, dataset dibagi menjadi tiga bagian, yaitu data training, validation dan data testing. Pembagian dataset yang digunakan dalam penelitian ini adalah 64:16:20, di mana 64% dari total data digunakan sebagai data training, 16% sebagai data validasi dan 20% sisanya digunakan sebagai data testing. Dengan total 3.434 citra, pembagian ini

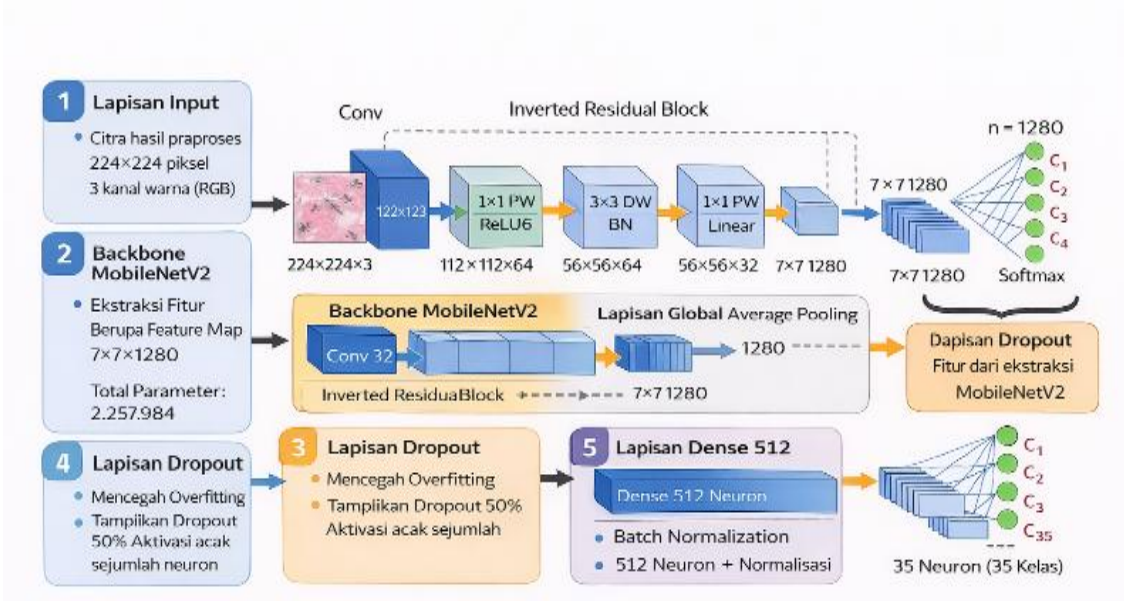
menghasilkan 2.197 citra sebagai data training, 550 citra sebagai data validasi dan 687 citra sebagai data testing. Pembagian dataset dilakukan secara proporsional untuk memastikan model memperoleh data pelatihan yang memadai serta data pengujian yang representatif dalam mensimulasikan kondisi penggunaan model di dunia nyata. Dataset hasil pembagian tersebut selanjutnya digunakan sebagai masukan pada proses pelatihan, pengujian, dan evaluasi model CNN MobileNetV2 dalam melakukan identifikasi karakter Aksara Jawi.

2.2 Preprocessing

Setelah dataset citra Aksara Jawi dikumpulkan, tahap selanjutnya yakni dilakukan pre-processing citra yang bertujuan untuk meningkatkan kualitas data sebelum proses identifikasi. Tahapan preprocessing meliputi pemotongan citra (cropping) untuk menghilangkan bagian yang tidak diperlukan, konversi grayscale untuk mengubah citra berwarna menjadi keabuan, noise removal untuk mengurangi gangguan pada citra, serta binerisasi (thresholding) untuk mempertegas perbedaan antara objek aksara dan latar belakang. Selanjutnya dilakukan segmentasi untuk memisahkan karakter aksara dari citra secara keseluruhan, normalisasi untuk menyeragamkan ukuran dan nilai piksel citra, serta augmentasi data untuk menambah variasi data pelatihan. Seluruh tahapan preprocessing ini dilakukan agar citra Aksara Jawi menjadi lebih bersih, seragam, dan optimal digunakan sebagai masukan pada proses ekstraksi fitur dan identifikasi menggunakan model Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2.

2.3 CNN Arsitektur MobileNetV2

Proses pengenalan citra Aksara Jawi dalam penelitian ini dilakukan dengan mengembangkan metode Convolutional Neural Network (CNN) menggunakan arsitektur MobileNetV2. Arsitektur CNN MobileNetV2 yang digunakan dalam penelitian ini terdiri dari beberapa lapisan utama yang disusun secara berurutan untuk mengekstraksi fitur citra Aksara Jawi dan melakukan proses identifikasi dan klasifikasi. Adapun bentuk arsitektur yang digunakan dapat dilihat pada gambar berikut



Gambar 3. Arsitektur CNN MobileNetV2

Arsitektur yang disajikan pada gambar 3 dapat dijelaskan sebagai berikut.

1. Lapisan Input

Lapisan input menerima citra hasil prapemrosesan dengan ukuran 224 × 224 piksel dan 3 kanal warna. Citra grayscale yang digunakan pada tahap praproses dikonversi ke dalam tiga kanal agar sesuai dengan kebutuhan arsitektur MobileNetV2 yang telah dilatih sebelumnya. Lapisan ini berfungsi sebagai pintu masuk data citra ke dalam jaringan tanpa melakukan proses komputasi.

2. Backbone MobileNetV2

Lapisan utama dalam arsitektur ini adalah MobileNetV2 (`include_top = false`) yang berfungsi sebagai feature extractor. Backbone ini menghasilkan keluaran berupa feature map berukuran $7 \times 7 \times 1280$ dengan total parameter sebesar 2.257.984. MobileNetV2 menerapkan konsep inverted residual dan linear bottleneck, serta depthwise separable convolution, sehingga mampu mengekstraksi fitur citra secara bertahap dan efisien. Proses ekstraksi fitur dilakukan secara multilayer, mulai dari fitur dasar hingga fitur kompleks yang merepresentasikan pola karakter Aksara Jawi.

3. Lapisan Global Average Pooling
Lapisan Global Average Pooling 2D digunakan untuk mereduksi dimensi feature map dari ukuran $7 \times 7 \times 1280$ menjadi vektor satu dimensi berukuran 1280. Proses ini dilakukan dengan menghitung nilai rata-rata pada setiap channel fitur. Penggunaan lapisan ini bertujuan untuk mengurangi jumlah parameter, mencegah overfitting, serta mempertahankan informasi global dari fitur yang telah diekstraksi.
4. Lapisan Dropout
Lapisan Dropout diterapkan setelah Global Average Pooling untuk mengurangi risiko overfitting dengan cara menonaktifkan sejumlah neuron secara acak selama proses pelatihan. Lapisan ini tidak menambah jumlah parameter, tetapi berperan penting dalam meningkatkan kemampuan generalisasi model.
5. Lapisan Fully Connected (Dense 512) dan Batch Normalization
Lapisan Dense dengan 512 neuron digunakan untuk mempelajari hubungan nonlinier dari fitur hasil ekstraksi MobileNetV2. Lapisan ini memiliki 655.872 parameter. Selanjutnya, Batch Normalization diterapkan untuk menstabilkan distribusi nilai aktivasi, mempercepat proses konvergensi, serta meningkatkan kestabilan pelatihan jaringan.
6. Lapisan Dropout dan Dense 256
Lapisan Dropout kembali digunakan untuk mengurangi overfitting, kemudian diikuti oleh lapisan Dense dengan 256 neuron yang berfungsi memperdalam proses pembelajaran fitur sebelum tahap klasifikasi akhir. Lapisan ini memiliki 131.328 parameter. Batch Normalization kembali diterapkan untuk menjaga kestabilan pembelajaran pada lapisan ini.
7. Lapisan Klasifikasi Akhir (Dense Softmax)
Lapisan terakhir adalah Dense layer dengan 35 neuron yang merepresentasikan jumlah kelas huruf Aksara Jawi. Lapisan ini menggunakan fungsi aktivasi Softmax untuk menghasilkan nilai probabilitas pada setiap kelas. Kelas dengan probabilitas tertinggi dipilih sebagai hasil akhir klasifikasi karakter Aksara Jawi.

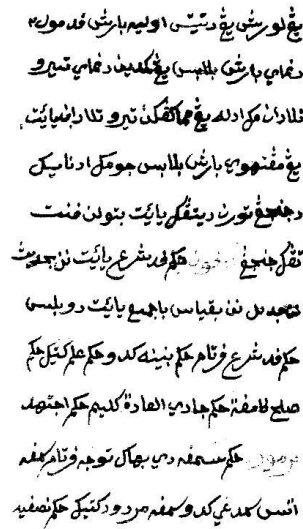
3. Hasil dan Pembahasan

Model pada penelitian ini dikembangkan dan dijalankan menggunakan bahasa pemrograman Python pada lingkungan komputasi Google Colab. Citra mentah diolah menjadi Citra latih pada penelitian ini setelah melalui proses Preprocessing agar meningkatkan akurasi model. Proses pelatihan model dilakukan dengan memanfaatkan arsitektur Convolutional Neural Network (CNN) MobileNetV2 untuk mengidentifikasi 35 kelas aksara Jawi.

3.1 Preprocessing

Tahap preprocessing citra naskah kuno aksara Jawi merupakan langkah penting dalam proses identifikasi huruf menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2. Tujuan dari tahap ini adalah untuk menghasilkan citra dengan kualitas yang baik, seragam, dan representatif sebelum digunakan dalam proses pelatihan model.

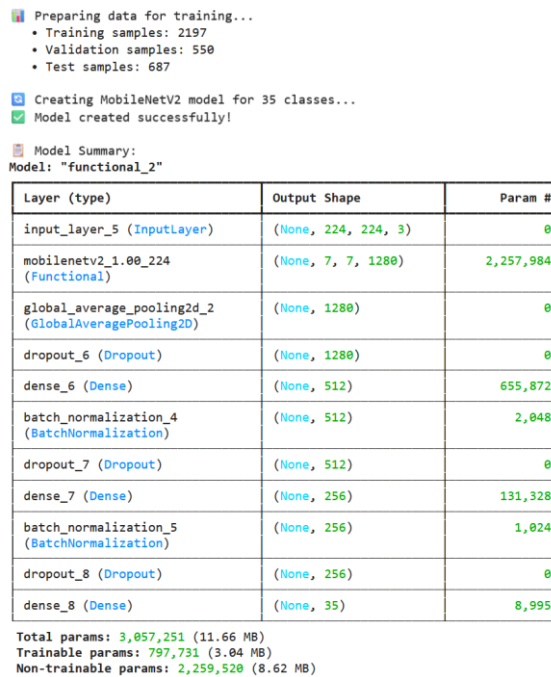
Gambar 4 merupakan hasil binerisasi pada tahapan preprocessing yang dilakukan dalam penelitian ini. Proses binerisasi citra menggunakan metode *Otsu Thresholding* yang disajikan pada Gambar 4 menunjukkan hasil pemisahan objek dan latar belakang pada citra. Gambar 4 merupakan keluaran hasil binerisasi citra, berupa citra biner yang hanya terdiri dari dua nilai intensitas, yaitu hitam dan putih. Hasil proses binerisasi menunjukkan bahwa objek utama, khususnya huruf Jawi, terlihat lebih kontras dibandingkan latar belakang. Penerapan metode Otsu bertujuan untuk menentukan nilai ambang secara otomatis sehingga proses pemisahan objek dan latar belakang dapat dilakukan secara optimal. Citra hasil binerisasi selanjutnya akan dilanjutkan ke tahap pengolahan berikutnya untuk meningkatkan ketepatan proses pendeteksian dan segmentasi huruf.



Gambar 4. Hasil Binerisasi Citra Mentah aksara jawi

3.2 Analisis Metode CNN Arsitektur MobilNetV2

Proses pelatihan model dilakukan dengan memanfaatkan arsitektur Convolutional Neural Network (CNN) MobileNetV2 untuk klasifikasi 35 kelas aksara Jawi. Model yang digunakan dalam penelitian ini adalah model "functional" yang memungkinkan perancangan arsitektur jaringan saraf lebih fleksibel dan kompleks, termasuk penggunaan model pra-latih (*pretrained model*) seperti MobileNetV2, serta penggabungan beberapa lapisan dengan alur data yang tidak selalu linier. Model functional ini disajikan pada gambar 5.



Gambar 5. Model CNN

Gambar 5 menggambarkan model ini dirancang untuk melakukan klasifikasi citra Aksara Jawi ke dalam 35 kelas dengan memanfaatkan arsitektur MobileNetV2 sebagai feature extractor Model menerima citra berukuran $224 \times 224 \times 3$ sebagai masukan, kemudian memanfaatkan MobileNetV2 pretrained sebagai feature extractor yang menghasilkan feature map berukuran $7 \times 7 \times 1280$. Sebagian besar parameter pada lapisan MobileNetV2 bersifat non-trainable, sehingga

bobot hasil pelatihan sebelumnya dipertahankan untuk meningkatkan stabilitas ekstraksi fitur dan mengurangi risiko overfitting.

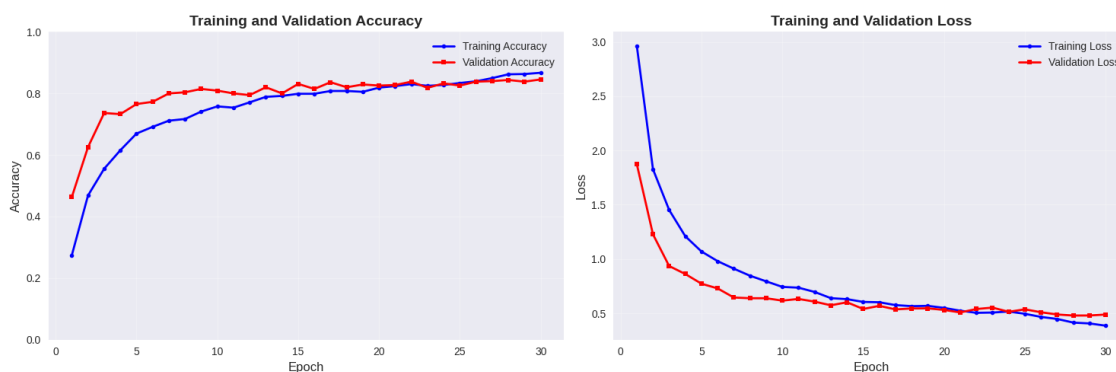
Tahap klasifikasi dilakukan melalui Global Average Pooling, diikuti oleh beberapa lapisan Dense, Batch Normalization, dan Dropout untuk meningkatkan kemampuan generalisasi model. Lapisan akhir menggunakan Dense dengan 35 neuron dan fungsi aktivasi Softmax untuk menghasilkan probabilitas setiap kelas aksara. Secara keseluruhan, model memiliki 3.057.251 parameter, dengan 797.731 parameter trainable dan 2.259.520 parameter non-trainable, yang menunjukkan bahwa model dirancang secara efisien dengan memanfaatkan keunggulan MobileNetV2 pretrained untuk tugas identifikasi Aksara Jawi.

```
Epoch 26: val_accuracy did not improve from 0.83818
69/69 ----- 136s 2s/step - accuracy: 0.8508 - loss: 0.4329 - val_accuracy: 0.8382 - val_loss: 0.5098 - learning_rate: 0.0010
Epoch 27/30
69/69 ----- 0s 1s/step - accuracy: 0.8513 - loss: 0.4374
Epoch 27: val_accuracy improved from 0.83818 to 0.84000, saving model to /content/drive/My Drive/tesis_devi/model_results/best_model.h5
WARNING:absl:You are saving your model as an HDF5 file via 'model.save()' or 'keras.saving.save_model(model)'. This file format is considered leg
69/69 ----- 144s 2s/step - accuracy: 0.8513 - loss: 0.4375 - val_accuracy: 0.8400 - val_loss: 0.4892 - learning_rate: 5.0000e-04
Epoch 28/30
69/69 ----- 0s 1s/step - accuracy: 0.8692 - loss: 0.4091
Epoch 28: val_accuracy improved from 0.84000 to 0.84364, saving model to /content/drive/My Drive/tesis_devi/model_results/best_model.h5
WARNING:absl:You are saving your model as an HDF5 file via 'model.save()' or 'keras.saving.save_model(model)'. This file format is considered leg
69/69 ----- 120s 2s/step - accuracy: 0.8691 - loss: 0.4091 - val_accuracy: 0.8436 - val_loss: 0.4795 - learning_rate: 5.0000e-04
Epoch 29/30
69/69 ----- 0s 1s/step - accuracy: 0.8761 - loss: 0.3875
Epoch 29: val_accuracy did not improve from 0.84364
69/69 ----- 119s 2s/step - accuracy: 0.8759 - loss: 0.3878 - val_accuracy: 0.8382 - val_loss: 0.4799 - learning_rate: 5.0000e-04
Epoch 30/30
69/69 ----- 0s 1s/step - accuracy: 0.8763 - loss: 0.3538
Epoch 30: val_accuracy improved from 0.84364 to 0.84545, saving model to /content/drive/My Drive/tesis_devi/model_results/best_model.h5
WARNING:absl:You are saving your model as an HDF5 file via 'model.save()' or 'keras.saving.save_model(model)'. This file format is considered leg
69/69 ----- 138s 2s/step - accuracy: 0.8762 - loss: 0.3543 - val_accuracy: 0.8455 - val_loss: 0.4888 - learning_rate: 5.0000e-04
Restoring model weights from the end of the best epoch: 28.
WARNING:absl:You are saving your model as an HDF5 file via 'model.save()' or 'keras.saving.save_model(model)'. This file format is considered leg
[✓] Training completed in 1:08:05.414339

🎉 TRAINING COMPLETED!
📊 Final Test Accuracy: 0.8224
🕒 Training Duration: 1:08:05.414339
📁 Results saved in: /content/drive/My Drive/tesis_devi/model_results
[✓] Training successful! Final accuracy: 0.8224
```

Gambar 6. Hasil Pelatihan CNN Arsitektur MobilenetV2

Proses pelatihan model dilakukan selama 30 epoch dengan menerapkan mekanisme Early Stopping dan Model Checkpoint untuk menyimpan bobot model terbaik berdasarkan nilai validation accuracy. Berdasarkan hasil pelatihan, diperoleh akurasi akhir pada data training sebesar 87,62% dengan nilai training loss sebesar 0,3543. Sementara itu, akurasi validasi tertinggi dicapai pada epoch ke-28 sebesar 84,36%, dengan validation loss sebesar 0,4795.



Gambar 7. Grafik training dan validation accuracy dan training dan validation loss


Grafik training dan validation accuracy menunjukkan adanya peningkatan performa model secara bertahap seiring dengan bertambahnya jumlah epoch. Tidak tampak perbedaan yang signifikan antara kedua kurva tersebut, yang mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik serta tidak mengalami overfitting secara signifikan. Temuan ini diperkuat oleh grafik training dan validation loss yang memperlihatkan tren penurunan nilai loss yang relatif stabil pada kedua dataset. Selain itu, penerapan learning rate scheduler memberikan kontribusi positif terhadap kestabilan proses pelatihan. Penurunan learning rate dari 0,001 menjadi 0,0005 membantu model mencapai proses konvergensi yang lebih optimal, khususnya pada epoch-epoch akhir.

Classification Report:

	precision	recall	f1-score	support
1	0.95	0.90	0.92	20
10	0.79	0.95	0.86	20
11	0.82	0.70	0.76	20
12	0.68	0.75	0.71	20
13	0.79	0.95	0.86	20
14	0.68	0.75	0.71	20
15	0.83	0.75	0.79	20
16	0.93	0.65	0.76	20
17	0.67	0.90	0.77	20
18	0.56	0.50	0.53	20
19	0.80	0.80	0.80	20
2	0.90	1.00	0.95	18
20	0.57	0.65	0.60	20
21	0.73	0.55	0.63	20
22	0.82	0.90	0.86	20
23	0.77	1.00	0.87	20
24	0.91	1.00	0.95	20
25	0.92	0.63	0.75	19
26	0.81	0.94	0.87	18
27	0.85	0.85	0.85	20
28	0.73	0.55	0.63	20
29	1.00	1.00	1.00	16
3	0.88	0.70	0.78	20
30	1.00	1.00	1.00	14
31	0.96	1.00	0.98	22
32	0.95	1.00	0.97	19
33	1.00	1.00	1.00	19
34	1.00	1.00	1.00	22
35	1.00	1.00	1.00	20
4	0.78	0.70	0.74	20
5	0.74	0.70	0.72	20
6	0.74	0.70	0.72	20
7	0.70	0.70	0.70	20
8	0.89	0.80	0.84	20
9	0.86	0.90	0.88	20
accuracy			0.82	687
macro avg	0.83	0.83	0.82	687
weighted avg	0.83	0.82	0.82	687

Gambar 7. Hasil Evaluasi Model

Setelah proses pelatihan selesai, model terbaik selanjutnya dievaluasi menggunakan data uji. Hasil evaluasi menunjukkan bahwa model mencapai akurasi pengujian sebesar 82,24%. Nilai ini menunjukkan bahwa arsitektur MobileNetV2 mampu melakukan klasifikasi citra aksara dengan tingkat ketepatan yang cukup baik, meskipun jumlah kelas yang digunakan relatif banyak. Berdasarkan hasil classification report, diperoleh nilai macro average precision sebesar 0,83, recall sebesar 0,82, dan f1-score sebesar 0,82. Nilai weighted average juga menunjukkan hasil yang sebanding, yang menandakan bahwa performa model relatif merata pada seluruh kelas, meskipun terdapat beberapa kelas dengan performa yang lebih rendah dibandingkan kelas lainnya. Beberapa kelas menunjukkan nilai precision dan recall yang sangat tinggi hingga mencapai 1,00, yang mengindikasikan bahwa model mampu mengenali pola visual aksara tertentu dengan sangat baik. Namun demikian, pada beberapa kelas lain masih ditemukan nilai recall dan f1-score yang lebih rendah. Hal ini diduga disebabkan oleh kemiripan bentuk antaraksara serta keterbatasan variasi citra pada kelas-kelas tertentu.



Gambar 8. Confusion Matrix

Hasil confusion matrix menunjukkan bahwa sebagian besar data uji berhasil diklasifikasikan dengan benar, yang ditunjukkan oleh dominasi nilai pada diagonal utama matriks. Kesalahan klasifikasi (misclassification) umumnya terjadi pada kelas-kelas aksara yang memiliki kemiripan bentuk visual, terutama pada struktur goresan dan kontur karakter. Meskipun demikian, jumlah kesalahan klasifikasi relatif kecil dibandingkan dengan jumlah prediksi yang benar. Hal ini menunjukkan bahwa fitur-fitur yang diekstraksi oleh arsitektur MobileNetV2 sudah cukup representatif dalam membedakan karakter aksara, meskipun masih terdapat peluang untuk meningkatkan performa model, khususnya pada kelas dengan nilai recall yang rendah.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 memiliki kemampuan yang memadai dalam mengidentifikasi aksara Jawi pada naskah kuno, meskipun jumlah kelas huruf yang digunakan relatif banyak dan memiliki tingkat kemiripan visual yang tinggi. Hasil akurasi pada data uji menunjukkan bahwa metode CNN arsitektur MobileNetV2 mampu mencapai tingkat akurasi sebesar 82,24% yang mengindikasikan bahwa model dapat mengidentifikasi fitur visual aksara Jawi dengan cukup baik. Namun masih terdapat beberapa kelas huruf aksara yang menunjukkan tingkat akurasi, nilai precision dan recall yang lebih rendah dibandingkan kelas lainnya, terutama huruf yang memiliki kemiripan visual seperti huruf 'da' (ڨ) dan 'dza' (ڤ), huruf 'ra' (ر) dan 'za' (ز), huruf 'fa' (ف), 'qa' (ق) dan 'pa' (پ). Tingginya tingkat keberhasilan model CNN ini diharapkan dapat mejadi salah satu solusi alternatif dalam upaya pelestarian naskah kuno khususnya yang berkaitan dengan teknologi informasi. Penelitian ini berkontribusi dalam pengembangan sistem identifikasi aksara Jawi berbasis deep learning yang efisien dan ringan serta mendukung upaya pelestarian naskah kuno, khususnya pada Dinas Kearsipan dan Perpustakaan Provinsi Sumatera Barat, dan diharapkan dapat menjadi rujukan bagi penelitian selanjutnya dengan pengembangan dataset yang lebih besar, perbandingan dengan arsitektur CNN lain, serta perluasan sistem hingga tahap pengenalan kata atau teks secara utuh.

Referensi

- [1] Kurniati, "Peran Perpustakaan Dalam Melestarikan Warisan Budaya dan Sejarah Lokal," *THE LIGHT: Journal of Librarianship and Information Science*, vol. Vol. 3 No. 102, Dec. 2023.
- [2] Herwansyah and N. U. Kulsum, "Perjalanan Sejarah dalam Naskah Kuno," pp. 6823–6828, 2024.
- [3] S. Amelia, N. U. Kalsum, and A. Berkah, "PENGARUH NASKAH KUNO TERHADAP PERKEMBANGAN BUDAYA LOKAL DAN TRADISI SASRA DI NUSANTARA," *Pendidikan Sejarah & Sejarah FKIP Universitas Jambi*, vol. 5, no. 1, 2025, doi: 10.22437/jejak.v5i1.44381.
- [4] R. Saputra, E. Rochmiatun, and W. R. Andhifani, "Preservasi naskah kuno : Sebuah kajian evaluasi Perpustakaan Pribadi Kemas Andi Syarifuddin di Kota Palembang," *Berkala Arkeologi*, vol. 45, no. 1, pp. 59–76, Apr. 2025, doi: 10.55981/jba.2025.6421.
- [5] A. N. L. Hanum, A. T. Priyadi, A. N. Hanum, and A. A. Akbar, "Peran library, archives, museums dalam pelestarian naskah kuno di Kalimantan Barat," *Berkala Ilmu Perpustakaan dan Informasi*, vol. 19, no. 1, pp. 66–82, Jun. 2023, doi: 10.22146/bip.v19i1.6294.
- [6] O. Rizkyantha, C. Afrina, M. Oktavia, U. Raden Fatah Palembang, and P. Indonesia, "Preservasi Naskah Kuno: Strategi Pelestarian Minimal untuk Mempertahankan Warisan Budaya," 2025. [Online]. Available: <https://journal.unilak.ac.id/index.php/pb/>
- [7] W. D. Pramana, "Strategi pelestarian naskah kuno di Dinas Perpustakaan dan Kearsipan Provinsi Jawa Timur," *Daluang: Journal of Library and Information Science*, vol. 2, no. 2, pp. 31–41, Nov. 2022, doi: 10.21580/daluang.v2i2.2022.10293.
- [8] T. Makmur, D. Abdurahman, R. Zulaikha, and D. Samsudin, "Tantangan utama preservasi naskah kuno berbasis digitisasi 1 2 3 4," *Berkala Ilmu Perpustakaan dan Informasi*, vol. 20, no. 1, pp. 193–209, 2024, doi: 10.22146/bip.v19i1.9321.
- [9] E. A. Barus and S. Mawaddah, "Sejarah Tulisan Arab-Melayu Warisan Budaya dan Identitas Islam di Nusantara," *Jurnal Penelitian Ilmu-Ilmu Sosial*, vol. 02, 2025, doi: 10.5281/zenodo.15715947.
- [10] Elmustian and M. Firdaus, "Filologi, Transformasi Teks, dan Filsafat Pendidikan: Strategi Pelestarian Budaya dalam Konteks Pendidikan Kontemporer," *Indonesian Research Journal on Education*, 2024.
- [11] M. Muhaemin, "Potensi dan Tantangan Naskah Kuno di Indonesia Sebagai Warisan Budaya Digital: Narrative Literature Review," *Pustablibia: Journal of Library and Information Science*, vol. 8, no. 1, pp. 1–17, Jul. 2024, doi: 10.18326/pustablibia.v8i1.1-17.
- [12] P. Xu, J. Wang, Y. Jiang, and X. Gong, "Applications of artificial intelligence and machine learning in image processing," *Front. Mater.*, vol. 11, 2024, doi: 10.3389/fmats.2024.1431179.
- [13] 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.
- [14] M. Kamal, F. Shaiara, C. M. Abdullah, S. Ahmed, T. Ahmed, and Md. H. Kabir, "Huruf: An Application for Arabic Handwritten Character Recognition Using Deep Learning," Dec. 2022, doi: 10.1109/ICCIT57492.2022.10054769.
- [15] M. G. Mahdi, A. Sleem, I. M. Elhenawy, and S. Safwat, "Enhancing the Recognition of Handwritten Arabic Characters through Hybrid Convolutional and Bidirectional Recurrent Neural Network Models," *Sustainable Machine Intelligence Journal*, vol. 9, pp. 34–56, Oct. 2024, doi: 10.61356/smij.2024.9382.