

ANALISA PERFORMA CONVOLUTION NEURAL NETWORK DALAM PENGENALAN TULISAN TANGAN AKSARA LONTARA

PERFORMANCE ANALYSIS OF CONVOLUTIONAL NEURAL NETWORK IN HANDWRITTEN LONTARA SCRIPT RECOGNITION

Ni Putu Irene Pasca Nurahdika¹, Joko Sutopo²

Informatika Fakultas Sains Dan Teknologi, Universitas Teknologi Yogyakarta^{1,2}

irenepasca98@gmail.com¹, jksutopo@uty.ac.id²

ABSTRACT

Lontara script is a cultural heritage of Nusantara that needs preservation through modern technology. This study implements a Convolutional Neural Network (CNN) to recognize handwritten Lontara script, consisting of 23 characters with various forms. The dataset comprises 7,452 training images and 3,726 validation images. The preprocessing stage includes normalization and data augmentation to enhance generalization. The CNN model consists of three convolutional layers, ReLU activation functions, dropout to prevent overfitting, and softmax in the output layer. Optimization is performed using the Adam algorithm with the categorical crossentropy loss function. The results show a training accuracy of 93.04% and a validation accuracy of 92.27%, with a significant reduction in loss. Graph analysis reveals consistency between training and validation data, demonstrating good generalization capability. This study confirms the effectiveness of CNN in recognizing Lontara script, supporting cultural heritage preservation through digitalization.

Keywords: Lontara Script, CNN, Cultural Heritage Digitalization.

ABSTRAK

Aksara Lontara merupakan warisan budaya Nusantara yang perlu dilestarikan melalui teknologi modern. Penelitian ini menerapkan Convolutional Neural Network (CNN) untuk mengenali tulisan tangan aksara Lontara, yang terdiri dari 23 karakter dengan berbagai variasi bentuk. Dataset terdiri dari 7.452 gambar pelatihan dan 3.726 gambar validasi. Tahap preprocessing mencakup normalisasi dan augmentasi data untuk meningkatkan generalisasi. Model CNN memiliki tiga lapisan konvolusi, fungsi aktivasi ReLU, dropout untuk mencegah overfitting, dan softmax di lapisan keluaran. Optimasi dilakukan menggunakan algoritma Adam dengan fungsi loss categorical crossentropy. Hasil menunjukkan akurasi pelatihan sebesar 93,04% dan validasi 92,27%, dengan nilai kerugian yang menurun signifikan. Analisis grafik menunjukkan konsistensi antara data pelatihan dan validasi, memperlihatkan kemampuan generalisasi yang baik. Penelitian ini membuktikan efektivitas CNN dalam pengenalan aksara Lontara, mendukung pelestarian warisan budaya melalui digitalisasi.

Kata Kunci: Aksara Lontara, CNN, Pelestarian Budaya, Pengenalan Pola.

PENDAHULUAN

Tulisan tangan aksara Lontara memiliki nilai budaya yang tinggi dalam sejarah dan tradisi masyarakat Bugis-Makassar di Indonesia YANG juga digunakan oleh masyarakat suku Mandar di Sulawesi Barat. Namun, pelestariannya menghadapi tantangan akibat minimnya dokumentasi digital dan rendahnya kesadaran masyarakat untuk mempelajarinya. (Handoko et al., 2024; Sahila et al., 2024.) Namun, dalam beberapa tahun terakhir, penggunaan aksara Lontara semakin berkurang seiring dengan perubahan zaman yang semakin mengarah pada digitalisasi (Lasido &

History, 2023.). Oleh karena itu, diperlukan strategi yang efektif untuk melestarikan aksara ini agar tetap dapat digunakan dan dikenali oleh generasi mendatang.

Pengenalan pola menjadi salah satu topik yang banyak diteliti dalam bidang kecerdasan buatan. Salah satu metode yang paling sering digunakan dalam pengenalan pola adalah Convolutional Neural Network (CNN). CNN dirancang khusus untuk mengolah data berupa citra dan memiliki kemampuan mengekstrak fitur secara otomatis tanpa memerlukan ekstraksi fitur manual (Dias Puspitasari & Anardani, 2023.). Tantangan yang

dihadapi dalam bidang pengenalan pola ini adalah digitalisasi aksara tradisional (Sazqiah et al., 2022.), seperti aksara Lontara, yang memiliki karakteristik unik dengan berbagai variasi bentuk huruf. Oleh karena itu, pendekatan yang cermat dan inovatif diperlukan untuk mengatasi kompleksitas ini (Rizal et al., 2023).

Penelitian ini bertujuan untuk mengeksplorasi potensi CNN dalam mengenali aksara Lontara dengan memanfaatkan arsitektur tiga lapisan konvolusi dan teknik dropout untuk meningkatkan kemampuan generalisasi model (Ripera, 2024). Dataset yang digunakan dalam penelitian ini berisi 23 kelas aksara dengan total 11.178 citra yang telah dibagi menjadi dua bagian, yaitu data pelatihan dan validasi. Dengan pendekatan ini, penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan sistem berbasis kecerdasan buatan dalam usaha melestarikan budaya lokal dan mengatasi berbagai tantangan dalam pengenalan aksara tradisional (Saneval Arhinza et al., 2024.).

Penelitian terkait pengenalan aksara dengan metode CNN telah banyak dilakukan sebelumnya. Contohnya, penelitian (Rahmawati et al., 2021) yang mengimplementasikan deep learning untuk mengenali aksara Sunda menggunakan CNN. Hasilnya menunjukkan bahwa penggunaan epoch sebanyak 500 dengan learning rate 0.1 dan optimasi algoritma ADAM memberikan akurasi tertinggi sebesar 98,03%. Sementara itu, penggunaan kernel 3x3 dengan epoch 100 dan learning rate 0.001 memberikan akurasi sebesar 96,71%. Perbandingan ini menunjukkan peningkatan pada data training dari 90% menjadi 96,71% dan data uji dari 76,19% menjadi 92,02%.

Penelitian lain oleh (Mayanda Mega Santoni et al., 2021) yang berjudul Penerapan Convolutional Neural Networks untuk Mesin Penerjemah Bahasa Daerah Minangkabau Berbasis Gambar berhasil menunjukkan bahwa model CNN mampu menghasilkan akurasi sebesar 98,97%

dalam mengklasifikasikan alfabet tercetak, 50,72% dalam OCR untuk teks, dan 75,78% dalam klasifikasi hasil penerjemahan dengan penerapan algoritma Levenshtein Distance.

Penelitian oleh (Rachmawanto & Andono, 2022) mengenai Deteksi Karakter Hiragana Menggunakan CNN menunjukkan bahwa CNN mampu mencapai akurasi sebesar 86,5% pada data training dan 95% pada validasi dengan menggunakan ukuran input dan jumlah epoch yang telah ditentukan. Akan tetapi, penelitian ini juga menemukan penurunan akurasi ketika jumlah data training dikurangi, menunjukkan pentingnya jumlah data yang memadai dalam model CNN.

Penelitian lain yang dilakukan oleh (Rahmawan et al., 2023) dalam Rekognisi Huruf Tulisan Tangan Menggunakan CNN menunjukkan bahwa CNN dapat menghasilkan performa yang sangat baik dengan memanfaatkan 2 lapisan konvolusi, 50 epoch, dan menggunakan algoritma optimisasi ADAM, yang menghasilkan akurasi hingga 99,5% pada fase pengujian model.

Dengan berbagai hasil penelitian yang telah dilakukan sebelumnya, kontribusi CNN dalam pengenalan tulisan tangan dan aksara tradisional semakin terbukti efektif. Oleh karena itu, penelitian ini memiliki peran penting untuk menggali dan mengembangkan metode CNN lebih lanjut dalam konteks pengenalan aksara tradisional seperti aksara Lontara.

Perbedaan penelitian terdahulu dengan penelitian yang saya lakukan terletak pada pendekatan dan fitur yang dikembangkan. Penelitian sebelumnya umumnya masih berfokus pada pembacaan per huruf dan sebagian menggunakan aplikasi MATLAB untuk pengenalan pola. Sementara itu, penelitian ini memanfaatkan aplikasi berbasis Python dengan kemampuan pembacaan per kata, serta dilengkapi fitur penerjemahan dari bahasa Indonesia ke bahasa Mandar, yang kemudian diterjemahkan ke dalam

penulisan aksara Lontara. Pendekatan ini tidak hanya lebih efisien tetapi juga memberikan nilai tambah dalam pelestarian aksara dan bahasa daerah.

TINJAUAN PUSTAKA

1. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu arsitektur jaringan saraf tiruan yang dirancang khusus untuk mengolah data citra. CNN memiliki keunggulan dalam mengekstrak fitur-fitur dari gambar secara otomatis tanpa memerlukan proses ekstraksi manual. Arsitektur dasar CNN terdiri dari tiga komponen utama, yaitu lapisan konvolusi (convolutional layer), lapisan pooling (pooling layer), dan lapisan fully connected (fully connected layer).

a. Lapisan Konvolusi (Convolutional Layer)

Lapisan ini berperan dalam mengekstrak fitur-fitur penting dari gambar melalui operasi konvolusi. Kernel atau filter akan bergerak melintasi citra input untuk menghasilkan feature map, yang merepresentasikan karakteristik gambar. Parameter penting dalam lapisan ini meliputi ukuran kernel, stride, dan padding, yang memengaruhi resolusi feature map.

b. Lapisan Pooling (Pooling Layer)

Pooling digunakan untuk mengurangi dimensi feature map, sehingga mengurangi jumlah parameter dalam jaringan dan meningkatkan efisiensi komputasi. Teknik pooling yang umum digunakan adalah max pooling dan average pooling. Max pooling memilih nilai maksimum dalam jendela tertentu, sedangkan average pooling menghitung rata-rata nilai dalam jendela tersebut.

c. Lapisan Fully Connected (Fully Connected Layer)

Lapisan ini berfungsi menggabungkan semua fitur yang telah diekstraksi dari lapisan sebelumnya untuk menghasilkan output akhir. Pada tahap ini, feature map diratakan menjadi satu

dimensi dan dihubungkan dengan neuron-neuron dalam lapisan fully connected. Proses ini memungkinkan jaringan untuk melakukan klasifikasi berdasarkan fitur-fitur yang telah diekstrak.

Melalui kombinasi ketiga lapisan tersebut, CNN mampu mengenali pola visual secara efektif, menjadikannya salah satu metode unggulan dalam pengenalan pola, termasuk tulisan tangan dan aksara tradisional.

2. Pengenalan Tulisan Tangan

Pengenalan tulisan tangan merupakan salah satu bidang penelitian yang banyak dikembangkan dalam teknologi kecerdasan buatan. Tujuan dari pengenalan tulisan tangan adalah mengubah tulisan tangan manusia menjadi bentuk digital yang dapat diproses oleh sistem komputer. Teknik-teknik yang digunakan dalam pengenalan tulisan tangan antara lain:

a. Metode berbasis Jaringan Saraf Tiruan

Teknik berbasis jaringan saraf tiruan, seperti CNN, menjadi pendekatan populer dalam pengenalan tulisan tangan. CNN memiliki kemampuan mengekstrak fitur kompleks dari citra tulisan tangan secara otomatis. Arsitektur ini memungkinkan jaringan untuk mengenali pola tulisan tangan meskipun terdapat variasi bentuk, ukuran, dan orientasi huruf.

b. Metode Klasik

Sebelum berkembangnya deep learning, metode klasik seperti Support Vector Machine (SVM), K-Nearest Neighbor (KNN), dan Hidden Markov Model (HMM) sering digunakan. Namun, metode ini memiliki keterbatasan dalam akurasi dan kemampuan generalisasi, terutama untuk data yang kompleks dan bervariasi.

c. Metode berbasis Deep Learning

Dengan hadirnya metode deep learning, akurasi pengenalan tulisan tangan meningkat signifikan. Penelitian-penelitian sebelumnya menunjukkan

bahwa penggunaan CNN dapat mencapai akurasi tinggi karena kemampuannya dalam mempelajari representasi fitur secara hierarkis, mulai dari fitur sederhana hingga fitur yang kompleks.

Penggunaan metode berbasis deep learning, khususnya CNN, telah membuka peluang besar dalam pengembangan sistem pengenalan tulisan tangan, termasuk aksara tradisional yang memiliki karakteristik visual unik.

3. Aksara Lontara

Aksara Lontara adalah sistem tulisan tradisional yang berasal dari suku Bugis di Sulawesi Selatan dan juga digunakan oleh masyarakat suku Mandar di Sulawesi Barat. Aksara ini memiliki nilai historis dan budaya yang tinggi sebagai salah satu warisan kebudayaan Nusantara.

a. Sejarah Aksara Lontara

Aksara Lontara berkembang sejak abad ke-15 sebagai sistem tulisan yang digunakan untuk mencatat berbagai aspek kehidupan masyarakat Bugis, seperti silsilah keluarga, perjanjian, dan karya sastra. Nama "Lontara" berasal dari kata "lontar", merujuk pada daun lontar yang digunakan sebagai media tulis pada masa lalu.

b. Karakteristik Aksara Lontara

Aksara Lontara termasuk dalam jenis aksara abugida, di mana setiap huruf dasar memiliki vokal inheren yang dapat diubah dengan menambahkan tanda diakritik. Aksara ini terdiri dari 23 huruf dasar, dengan variasi bentuk yang khas dan unik. Setiap huruf memiliki lekukan dan garis yang saling terhubung, sehingga menambah kompleksitas visualnya.

c. Kompleksitas Visual Aksara Lontara


Kompleksitas visual aksara Lontara terletak pada bentuk huruf yang mirip satu sama lain dengan sedikit perbedaan pada lengkungan atau garis. Selain itu, variasi tulisan tangan dari individu ke individu turut menambah tantangan dalam proses digitalisasi dan

pengenalan aksara ini. Dibandingkan aksara Latin, aksara Lontara memiliki tingkat keunikan yang lebih tinggi, sehingga memerlukan pendekatan teknologi yang cermat dan presisi dalam proses pengenalnya.

Dengan memahami sejarah, karakteristik, dan tantangan visual aksara Lontara, penelitian ini bertujuan untuk mengatasi permasalahan digitalisasi melalui pendekatan berbasis Convolutional Neural Network (CNN) sebagai langkah strategis dalam melestarikan aksara ini secara digital.

METODE

Penelitian ini dilakukan secara terstruktur agar mencapai hasil yang diinginkan dengan menjelaskan langkah-langkah yang dibutuhkan. Setiap Langkah penelitian ini dijelaskan pada Gambar 1 dibawah ini.



Gambar 1. Kerangka Penelitian

A. Instrumen Penelitian

1. Data Penelitian

Dalam pengumpulan data ada beberapa tahapan yang dilakukan sebagai berikut:

1. Sumber Data

Dataset aksara Lontara saya dapatkan melalui Kaggle, berupa data gambar dan menanyakan langsung pada salah seorang warga lokal tentang kebenaran pola penulisan aksara Lontara yang saya dapatkan, berikut ini merupakan tampilan aksara lontara.



Gambar 2. Bentuk Huruf Aksara Lontara

Sedangkan untuk Data Bahasa Mandar saya temukan melalui Googlescholar berupa Kamus Bahasa Mandar-Indonesia (Muthalib Abdul, 1977), berikut ini merupakan tampilan kamus bahasa mandar.



Gambar 3 Kamus Bahasa Mandar-Indonesia


2. Waktu Pengumpulan Data

Pengumpulan data dilakukan selama 1 minggu melalui internet dan proses konfirmasi pada warga lokal juga membutuhkan waktu 1 minggu melalui Whatsapp.

B. Analisis Perancangan

1. Dataset Aksara Lontara

Penelitian ini menggunakan dataset aksara Lontara yang terbagi atas 2 yaitu train dan validasi yang masing masing berisi 23 folder jenis huruf aksara Lontara. Pada folder train terdapat 7.452 data citra huruf Lontara dan pada folder validasi terdapat 3.726 data citra huruf Lontara. Seperti yang ditunjukkan pada Gambar 4. dibawah ini.



Gambar 4. Dataset Aksara Lontara

2. Arsitektur Model

Arsitektur model adalah alur pengolahan dataset menggunakan metode CNN pada Web Pengenalan Aksara Lontara, Seperti digambarkan pada Gambar 5. dibawah ini.



Gambar 5. Alur Pengolahan Dataset Aksara Lontara

Pada penelitian ini, dataset gambar aksara Lontara disiapkan dan digunakan sebagai data pelatihan untuk melatih model CNN. Dataset ini kemudian diolah oleh model untuk menghasilkan file matriks yang berfungsi sebagai basis data sistem. File matriks tersebut nantinya akan digunakan oleh sistem untuk membaca dan menampilkan hasil terjemahan aksara Lontara dari bahasa Mandar. Sebagai tambahan, gambar visualisasi alur pengolahan dataset aksara Lontara disediakan untuk mempermudah pemahaman proses ini.

C. Kebutuhan Fungsional dan Nonfungsional

1. Kebutuhan Fungsional

Kebutuhan Fungsional adalah Gambaran aktivitas system aplikasi untuk kebutuhan pengguna. Berikut ini merupakan kebutuhan fungsional untuk penggunaan:

- Pengguna dapat menerjemahkan bahasa Indonesia ke dalam bahasa Mandar

- b. Pengguna dapat mengetahui penulisan aksara Lontara untuk hasil terjemahan bahasa Mandar.

2. Kebutuhan Nonfungsional

Kebutuhan Nonfungsional adalah kebutuhan system yang berfokus pada alat yang digunakan, seperti perangkat keras, perangkat lunak, informasi serta pengguna sebagai objek analisis kekurangan dan kebutuhan yang harus dipenuhi dalam perancangan system yang akan diterapkan.

a. Perangkat Keras

1. Laptop Spesifikasi: AMD RYZEN 5, RAM 8 GB, SSD

2. Smartphone

b. Perangkat Lunak

1. Python
2. Anaconda
3. Jupyter Notebook
4. VsCode

c. Informasi

Segala fasilitas serta informasi yang ditampilkan akan sangat berguna dan membantu system sehingga dalam pengklasifikasian citra huruf Lontara dilakukan dengan lebih sesuai.


d. Pengguna

Aspek kebutuhan pengguna yaitu kemudahan dalam mengklasifikasi citra huruf Lontara.

D. Pembangunan Model

Pembuatan model melibatkan dua tahap utama, yaitu tahap pelatihan dan tahap pengujian. Pada tahap pelatihan, data latih berupa citra aksara Lontara diolah menggunakan metode Convolutional Neural Network (CNN) untuk membangun model pembelajaran mesin. Model yang dihasilkan dari proses ini akan digunakan untuk mengenali aksara Lontara secara otomatis. Setelah model selesai dilatih, tahap berikutnya adalah pengujian. Tahap ini bertujuan untuk mengevaluasi performa model dalam mengenali aksara Lontara dengan menggunakan data uji berupa citra aksara yang belum pernah dilihat oleh model sebelumnya.

Model CNN yang digunakan pada penelitian ini merupakan salah satu bidang ilmu Deep Learning yang digunakan untuk klasifikasi citra, yang terbagi berdasarkan kesamaan serta kemampuan pengenalan adegan. Seperti ditampilkan pada Gambar 6. dibawah ini.



Gambar 6. Alur Klasifikasi

1. Preprocessing Data

Tahap preprocessing bertujuan untuk menyiapkan dataset aksara Lontara agar dapat diproses oleh model CNN secara optimal. Langkah-langkah yang dilakukan meliputi:

a. Normalisasi Data

Setiap nilai piksel citra dinormalisasi ke dalam rentang 0-1 dengan membagi nilai piksel asli dengan 255 untuk mempercepat proses pelatihan.

b. Resizing

Seluruh citra diubah ke ukuran seragam yang sesuai dengan input layer model CNN, seperti 64x64 piksel, agar komputasi menjadi lebih efisien.

c. Augmentasi Data

Teknik augmentasi seperti rotasi, flipping horizontal/vertikal, dan zooming diterapkan untuk menambah variasi data dan menghindari overfitting.

d. Pembagian Dataset

Dataset dibagi menjadi dua bagian utama:

1. Training Set


Berisi 7.452 data citra untuk melatih model.

2. Validation Set

Berisi 3.726 data citra untuk mengevaluasi performa model selama proses pelatihan.

2. Arsitektur Model CNN

CNN memiliki beberapa lapisan konvolusi, Lapisan pooling, dan juga lapisan fully connected. Arsitektur model CNN yang digunakan digambarkan seperti pada Gambar 7. dibawah ini.



Gambar 7. Arsitektur Model CNN

Arsitektur Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini terdiri dari 3 lapisan konvolusi, 3 lapisan pooling, serta 3 fully connected layer, dengan salah satunya dilengkapi lapisan dropout untuk mencegah overfitting. Pemilihan arsitektur yang sederhana ini bertujuan untuk mengoptimalkan efisiensi waktu selama proses pelatihan, namun tetap mampu menjalankan tugas klasifikasi dataset aksara Lontara dengan baik.

3. Evaluasi Performa

Evaluasi performa model dilakukan menggunakan empat metrik evaluasi utama, yaitu Akurasi, Presisi, Recall, dan F1-Score. Masing-masing metrik digunakan untuk menilai kualitas prediksi model berdasarkan data validasi. Penjelasan setiap metrik adalah sebagai berikut:

1. Akurasi

Akurasi mengukur seberapa sering model melakukan prediksi yang benar dibandingkan dengan total jumlah data yang diuji. Akurasi memberikan gambaran umum tentang performa model dalam mengklasifikasikan seluruh kelas yang ada.

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Data}}$$

Berdasarkan hasil penelitian, model mencapai akurasi validasi tertinggi sebesar 92,97%, yang menunjukkan

bahwa sebagian besar prediksi yang dilakukan oleh model sudah benar

2. Presisi

Presisi digunakan untuk menilai ketepatan model dalam mengklasifikasikan sebuah kelas tertentu. Metrik ini fokus pada jumlah prediksi positif yang benar dibandingkan dengan total prediksi positif yang dibuat. Presisi sangat penting dalam menghindari kesalahan klasifikasi positif (false positive).

$$\text{Presisi} = \frac{\text{True Positive (TP)}}{\text{True Positive (TP)} + \text{False Positive (FP)}}$$

3. Recall

Recall, atau dikenal juga sebagai Sensitivity atau True Positive Rate, mengukur kemampuan model dalam menemukan semua contoh positif yang ada. Metrik ini fokus pada jumlah data positif yang berhasil diprediksi benar dibandingkan dengan seluruh data positif sebenarnya.

$$\text{Recall} = \frac{\text{True Positive (TP)}}{\text{True Positive (TP)} + \text{False Negative (FN)}}$$

4. F1-Score

F1-Score adalah rata-rata harmonis antara presisi dan recall. Metrik ini memberikan keseimbangan antara kedua metrik tersebut, terutama ketika terdapat ketidakseimbangan jumlah data antar kelas. Nilai F1-Score yang lebih tinggi menunjukkan bahwa model memiliki performa yang baik dalam klasifikasi.

$$\text{F1-Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}}$$

Berdasarkan Evaluasi Performa yang dilakukan menunjukkan bahwa model CNN mampu mengenali aksara Lontara dengan performa yang baik, ditunjukkan oleh akurasi validasi sebesar 92,97%. Selain itu, perhitungan presisi, recall, dan F1-Score dapat memastikan bahwa performa model konsisten, seimbang, dan mampu mengatasi kompleksitas karakter aksara Lontara.

HASIL DAN PEMBAHASAN

Hasil dari penelitian ini adalah pada Epoch ke-12 model mencapai hasil akurasi validasi tertinggi yaitu 92,97% dan loss validasi terendah sebesar 0,2429. Model menunjukkan performa yang sangat baik dalam pengenalan setiap 23 karakter Aksara Lontara, dengan Tingkat kesalahan yang cenderung rendah. Dengan hasil ini model telah berhasil belajar fitur-fitur dari data train serta mampu menggeneralisasi dengan baik dari data validasi. Seperti ditampilkan pada Gambar 8. berikut ini.


```

epoch 1/50 ..... - 67s 281ms/step - loss: 2.6338 - accuracy: 0.3853 - val_loss: 1.5974 - val_accuracy: 0.4458
epoch 2/50 ..... - 32s 135ms/step - loss: 1.5342 - accuracy: 0.4667 - val_loss: 1.0095 - val_accuracy: 0.6680
epoch 3/50 ..... - 33s 143ms/step - loss: 0.9985 - accuracy: 0.6382 - val_loss: 0.6594 - val_accuracy: 0.7925
epoch 4/50 ..... - 33s 143ms/step - loss: 0.7362 - accuracy: 0.7207 - val_loss: 0.6664 - val_accuracy: 0.7952
epoch 5/50 ..... - 33s 135ms/step - loss: 0.6137 - accuracy: 0.7817 - val_loss: 0.5205 - val_accuracy: 0.8272
epoch 6/50 ..... - 32s 137ms/step - loss: 0.5385 - accuracy: 0.8132 - val_loss: 0.4329 - val_accuracy: 0.8233
epoch 7/50 ..... - 32s 137ms/step - loss: 0.4639 - accuracy: 0.8364 - val_loss: 0.5225 - val_accuracy: 0.8086
epoch 8/50 ..... - 32s 136ms/step - loss: 0.4155 - accuracy: 0.8529 - val_loss: 0.4956 - val_accuracy: 0.8557
epoch 9/50 ..... - 32s 136ms/step - loss: 0.3812 - accuracy: 0.8674 - val_loss: 0.4420 - val_accuracy: 0.8612
epoch 10/50 ..... - 32s 135ms/step - loss: 0.4251 - accuracy: 0.8885 - val_loss: 0.4288 - val_accuracy: 0.8769
epoch 11/50 ..... - 32s 137ms/step - loss: 0.3858 - accuracy: 0.8961 - val_loss: 0.4827 - val_accuracy: 0.8888
epoch 12/50 ..... - 30s 129ms/step - loss: 0.2928 - accuracy: 0.9018 - val_loss: 0.4399 - val_accuracy: 0.9144
epoch 13/50 ..... - 36s 156ms/step - loss: 0.2815 - accuracy: 0.9022 - val_loss: 0.3176 - val_accuracy: 0.9018
epoch 14/50 ..... - 35s 149ms/step - loss: 0.2555 - accuracy: 0.9138 - val_loss: 0.3183 - val_accuracy: 0.8999
epoch 15/50 ..... - 33s 142ms/step - loss: 0.2894 - accuracy: 0.9254 - val_loss: 0.3898 - val_accuracy: 0.8992
epoch 16/50 ..... - 34s 147ms/step - loss: 0.2216 - accuracy: 0.9224 - val_loss: 0.4447 - val_accuracy: 0.8888
epoch 17/50 ..... - 31s 135ms/step - loss: 0.2153 - accuracy: 0.9277 - val_loss: 0.2782 - val_accuracy: 0.9208
epoch 18/50 ..... - 31s 148ms/step - loss: 0.2811 - accuracy: 0.9162 - val_loss: 0.2883 - val_accuracy: 0.9168
epoch 19/50 ..... - 38s 129ms/step - loss: 0.1832 - accuracy: 0.9364 - val_loss: 0.3599 - val_accuracy: 0.9042
epoch 20/50 ..... - 31s 133ms/step - loss: 0.1743 - accuracy: 0.9376 - val_loss: 0.3373 - val_accuracy: 0.9087
epoch 21/50 ..... - 35s 151ms/step - loss: 0.1856 - accuracy: 0.9357 - val_loss: 0.3084 - val_accuracy: 0.9133
epoch 22/50 ..... - 34s 148ms/step - loss: 0.1818 - accuracy: 0.9372 - val_loss: 0.2578 - val_accuracy: 0.9263
epoch 23/50 ..... - 32s 137ms/step - loss: 0.1588 - accuracy: 0.9481 - val_loss: 0.2838 - val_accuracy: 0.9275
epoch 24/50 ..... - 32s 136ms/step - loss: 0.1459 - accuracy: 0.9485 - val_loss: 0.2389 - val_accuracy: 0.9423
epoch 25/50 ..... - 31s 133ms/step - loss: 0.1324 - accuracy: 0.9471 - val_loss: 0.2787 - val_accuracy: 0.9382
epoch 26/50 ..... - 33s 143ms/step - loss: 0.1491 - accuracy: 0.9528 - val_loss: 0.2943 - val_accuracy: 0.9311
epoch 27/50 ..... - 34s 145ms/step - loss: 0.1398 - accuracy: 0.9544 - val_loss: 0.4282 - val_accuracy: 0.8880
epoch 28/50 ..... - 34s 147ms/step - loss: 0.1494 - accuracy: 0.9493 - val_loss: 0.3983 - val_accuracy: 0.9344
epoch 29/50 ..... - 34s 144ms/step - loss: 0.1355 - accuracy: 0.9534 - val_loss: 0.4822 - val_accuracy: 0.9053
epoch 30/50 ..... - 34s 144ms/step - loss: 0.1355 - accuracy: 0.9534 - val_loss: 0.4822 - val_accuracy: 0.9053

```

Gambar 8. Hasil Pelatihan Model CNN

Grafik hasil akurasi dan loss selama 20 epoch untuk data pelatihan dan validasi ditunjukkan pada Gambar 9. dibawah ini.



Gambar 9. Grafik Hasil Pelatihan Model CNN

Pada grafik akurasi, terlihat peningkatan signifikan pada beberapa epoch awal, kemudian stabil mendekati 90% pada epoch ke-20 untuk kedua set data, yang menunjukkan bahwa grafik loss memperlihatkan penurunan tajam pada beberapa epoch pertama, mengindikasikan bahwa model dengan cepat mempelajari pola dan mengurangi kesalahan. Setelahnya, nilai loss stabil di bawah 0,5, menunjukkan model tidak hanya akurat tetapi juga konsisten dalam memprediksi data validasi dengan tingkat kesalahan yang rendah. Grafik ini juga mengindikasikan bahwa model terlatih dengan baik tanpa menunjukkan tanda-tanda overfitting, karena akurasi dan loss pada data validasi mengikuti pola yang serupa dengan data pelatihan, model telah belajar dengan baik.

Berikut merupakan tampilan untuk website pengenalan aksara Lontara yang menerjemahkan bahasa Indonesia kedalam bahasa mandar serta menampilkan prediksi aksara Lontara yang disesuaikan dengan terjemahan bahasa Mandarin. Seperti terlihat pada gambar 10 berikut ini.

- Desember 2023 E-ISSN:2807-7628
AKSARA LONTARA
MAKASSAR: JEMBATAN
WARISAN BUDAYA ETNIS
BUGIS-MAKASSAR.
- Mayanda Mega Santoni, Nurul Chamidah, Desta Sandya Prasvita, Helena Nurramdhani Irmanda, Ria Astriratma, & Reza Amarta Prayoga. (2021). Penerapan Convolutional Neural Networks Untuk Mesin Penerjemah Bahasa Daerah Minangkabau Berbasis Gambar. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(6), 1153–1160.
<https://doi.org/10.29207/Resti.V5i6.3614>
- Rachmawanto, E. H., & Andono, P. N. (2022). Deteksi Karakter Hiragana Menggunakan Metode Convolutional Neural Network. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 11(3), 183–191.
<https://doi.org/10.23887/Janapati.V11i3.50144>
- Rahmawan, F., Habibi, R., Yusril, M., & Setyawan, H. (2023). Rekognisi Huruf Tulisan Tangan Menggunakan Convolutional Neural Network. In *Jurnal Sistem Cerdas (Vol. 6, Issue 3)*.
- Rahmawati, S. N., Hidayat, E. W., & Mubarak, H. (2021). IMPLEMENTASI DEEP LEARNING PADA PENGENALAN AKSARA SUNDA MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK. *INSERT: Information System And Emerging Technology Journal*, 2(1).
- Ripera, G. E. (2024). IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEURAL NETWORK PADA PENGENALAN AKSARA SUNDA SWARA PANGLAYAR. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(1).
<https://doi.org/10.23960/Jitet.V12i1.3871>
- Rizal, M. H., Bukhari, A., & Teknologi Akba Makassar, U. (2023). Pengembangan Game Edukasi Pengenalan Aksara Lontara Menggunakan Metode Game Development Life Cycle. *Jurnal Minfo Polgan*, 12(2).
<https://doi.org/10.33395/Jmp.V12i2.12413>
- Saneval Arhinza, R., Puspita Sari, A., Ali Akbar, F., Ilmu Komputer, F., Pembangunan Nasional, U., & Timur, J. (2024). Klasifikasi Citra Aksara Lontara Menggunakan K-NN Dan Ekstraksi Fitur HOG. In *Generation Journal (Vol. 8, Issue 2)*.
<https://www.kaggle.com/datasets/Asrulsaid/Aksara-Lontara>
- Sazqiah, N. P., Mulyani, Y., Muhammad, M. A., Martinus, D., Sukmana, I., Forda Nama, G., Huda, Z., Septiana, T., Kurniawan, P., & Djausal, G. P. (2022). Seminar Nasional Keinsinyuran (SNIP) Pengenalan Aksara Lampung Menggunakan Metode CNN (Convolutional Neural Network). In *Prosiding Seminar Nasional Keinsinyuran (SNIP (Vol. 2, Issue 1)*.

Website

Asrul Said (2022) Kaggle.com dari
<https://www.kaggle.com/datasets/asrulsaid/aksara-lontara>,