

ROFINUS ARYANTO

by Alfian Indra

Submission date: 09-May-2023 10:33AM (UTC+0900)

Submission ID: 2088106029

File name: 307-Article_Text-815-2-2-20230505.pdf (608.1K)

Word count: 3108

Character count: 19476



Penerapan Deep Learning untuk Pengenalan Tulisan Tangan Bahasa Akasara Lota Ende dengan Menggunakan Metode Convolutional Neural Networks (CNN)

Rofinus Aryanto^{1✉}, Mochmad Alfian Rosid², Suhendro Busono³

¹Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

Rofinusaryanto01@email

Abstrak

12
Aksara Lota merupakan turunan dari aksara Bugis. Orang Bugis yang hidup di Ende membawa peradaban dan budaya, termasuk aksaranya. Menurut catatan sejarah, naskah Lota berakhir sekitar abad ke-16, dan pada masa pemerintahan Raja XIV Goa, I Mangrangi Daeng Manrabia bergelar Sultan Alauddin (1593- 1639). Selama proses adaptasi, aksara Ende dikembangkan setelah sistem Ende menjadi aksara Lota. Aksara Ende awalnya ditulis menggunakan ujung pisau pada atas kertas wunu koli (daun lontar) sebelum kertas tadi masuk ke Nusantara. Aksara Lontar sebenarnya asal menurut luar wilayah Flores yaitu Bugis yg dikenal menggunakan Aksara Lontar (aksara Bugis).Media komunikasi pada tahun 90-an. Metode yang digunakan dalam penelitian yakni metode prediksi pengenalan menggunakan algoritma Convolutional Neural Network (CNN). Data yang digunakan berasal dari tulisan tangan responden yang dipindai dengan total banyaknya data sebanyak 700 citra data. Berdasarkan pengujian diketahui bahwa performa neural network dipengaruhi oleh jumlah iterasi. Performa akurasi meningkat pada iterasi ke-0 sampai dengan iterasi ke-20, akan tetapi untuk iterasi ke-40 sampai dengan iterasi ke-100 tidak mengalami perubahan yang cukup signifikan, akurasi dalam rentang iterasi 40-100 cukup stabil berada pada satu titik. Hasil dari pengujian algoritma CNN menggunakan bahasa pemrograman python mendapatkan akurasi 100%.

Kata kunci: Data Mining; Text Mining; Deep Learning; Convolutional Neural Networks.

JIDT is licensed under a Creative Commons 4.0 International License.



1. Pendahuluan

Aksara Lota merupakan turunan dari aksara Bugis. Orang Bugis yang hidup di Ende membawa peradaban dan budaya, termasuk aksaranya. Menurut catatan sejarah, naskah Lota berakhir sekitar abad ke-16, dan pada masa pemerintahan Raja XIV Goa, I Mangrangi Daeng Manrabia bergelar Sultan Alauddin (1593- 1639). Selama proses adaptasi, aksara Ende dikembangkan setelah sistem Ende menjadi aksara Lota [1]. Aksara Ende awalnya ditulis menggunakan ujung pisau pada atas kertas wunu koli (daun lontar) sebelum kertas tadi masuk ke Nusantara. Aksara Lontar sebenarnya asal menurut luar wilayah Flores yaitu Bugis yg dikenal menggunakan Aksara Lontar (aksara Bugis).Media komunikasi pada tahun 90-an. Hanya beberapa orang saja yg mampu membacanya, & hanya dalam program-program eksklusif saja. Aksara Lota Ende memakai pendekatan jenis alfabet Latin & mempunyai daya tarik pengembangan yg lebih fungsional yg akan dinikmati sang generasi belia Ende, lantaran alfabet -hurufnya akan permanen tidak terhapuskan& lestari. Huruf latin berbentuk alfabet A-Z biasanya dikenal sang generasi belia Ende & warga Indonesia [2]. Dengan ini bertujuan untuk mendigitalkan karakter yang dihafal dan bertujuan untuk membangun sistem pengenalan citra digital menggunakan metode Convolutional Neural Network (CNN). Ada beberapa pekerjaan pada klasifikasi citra digital. Deep Learning Karakter Devanagari Menggunakan Journal of Convolutional Neural Network Untuk Pengenalan Karakter Tulisan Tangan Bahasa aksara Lota Ende (membandingkan metode MLP dan CNN), Convolutional Neural Network untuk Deteksi Karakter Arab di Lapangan Medis dengan Convolutional Neural Network dengan Studi CNN % Akurasi Gambar Studi Pendukung pilihan CNN sebagai algoritma klasifikasi dan studi yang membandingkan model CNN yang berbeda menghasilkan akurasi 96% hingga 100% [3].

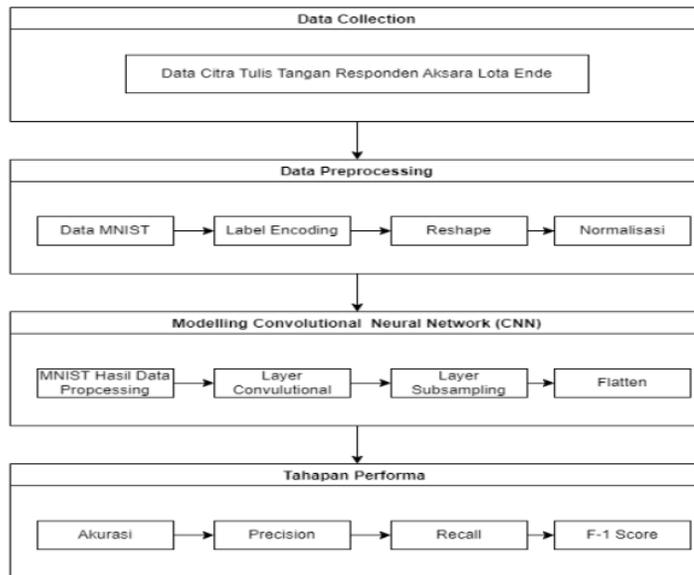
Pengenalan pola citra merupakan salah satu kemampuan yang dimiliki oleh sebuah komputer. Salah satu bidang studi yang mempelajari proses pengolahan gambar, dimana baik masukan maupun keluarannya berbentuk berkas citra digital. Foto merupakan contoh gambar yang dapat diolah secara mudah melalui perangkat lunak tertentu [4]. Tulisan tangan yang berbentuk pola angka memiliki bentuk yang tidak pasti atau tidak konsisten jika dibandingkan dengan mesin yang mencetak pola angka. Bahkan antara satu orang dengan yang lain berbentuk sama pasti akan menghasilkan pola yang berbeda-beda pada setiap angka yang sama. Keunikan inilah yang membuat tulisan tangan berpola angka lebih sulit dikenali dibandingkan dengan mesin yang mencetak pola angka [5]. Model pembelajaran untuk kasus tersebut akan lebih baik dengan menerapkan konsep jaringan syaraf tiruan dengan berbagai banyak lapisan dan dengan model tersebut, maka akan lebih baik lagi dapat memanfaatkan performa komputasi yang cepat. Oleh karena itu, perlu menggunakan teknik deep learning. Deep Learning adalah cabang dari machine learning yang menggunakan algoritma yang terinspirasi oleh struktur otak manusia[6].Pengenalan tulisan tangan bahasa aksara Lota ende dapat dilakukan dengan menggunakan pendekatan deep learning dengan algoritma CNN. Metode Neural Network adalah salah satu pendekatan pembelajaran terawasi yang telah mendapatkan popularitas yang cepat dalam beberapa tahun terakhir. Itu karena kinerjanya. Ini adalah jaringan saraf yang sangat khusus. Salah satu faktor yang mempengaruhi performansi atau nilai presisi yang dihasilkan adalah banyaknya iterasi. salah satu jenis deep learning yang memiliki performa terbaik dalam mengenali dan mengklasifikasi citra adalah Convolutional Neural Network [7]. CNN adalah hasil pengembangan algoritma jaringan saraf yang dirancang khusus untuk memproses data piksel dan gambar visual. Convolutional Neural Network (CNN) adalah evolusi dari multi-layer perceptron (MLP) yang dirancang untuk mengelola data dua dimensi, dan karena kedalaman jaringan yang dalam dan banyak aplikasi dalam gambar, jenis jaringan saraf yang dalam milik Untuk klasifikasi citra ini, MLP tidak cocok karena tidak menyimpan informasi khusus dari data citra dan setiap piksel dapat dianggap sebagai fitur independen. Jadi Andamendapatkan hasil yang buruk [8]. Tensorflow adalah framework Machine Learning yang dapat menjadi teman terbaik jika anda adalah penggemar bidang AI (artificial intelligence), atau deep learning dalam hal bekerja dengan data. Tensorflow membantu membuat jaringan saraf skala besar (jaringan buatan yang terlihat seperti otak manusia) [9].

Menurut penelitian sebelumnya membahas mengenai aksara Jawa dan Bali yang menghasilkan akurasi klasifikasi sebesar 38 % hingga 80%. Penelitian tersebut dihadapkan oleh beberapa permasalahan yaitu transformasi citra, perbedaan skala citra, dan noise reduction [10]. Adapun penelitian pengenalan tulisan tangan menggunakan ekstraksi Fitur bentuk dengan Chain Code sehingga didapatkan hasil pengujian dengan tingkat akurasi terbaik pada model citra 7x7 dengan nilai akurasi freeman chain code 99.75%, differential chain code 99.75%, dan vertex chain code 98.6% [11]. Penelitian yang menggunakan metode Convolutional Neural Network terhadap pengenalan huruf dan angka tunggal sebanyak 184 citra uji. Diperoleh jawaban benar sebanyak 153 buah citra dan jawaban salah sebanyak 31 buah citra sedangkan dengan 191 data uji berupa huruf dan angka mendapatkan jumlah jawaban yang benar sebanyak 158 buah citra dan jawaban salah sebanyak 33 buah citra [12] Penelitian ini bertujuan untuk mengembangkan model untuk pengenalan Tulisan tangan Aksara Lota Ende. Penelitian ini dikembangkan dengan penerapan algoritma CNN menggunakan bahasa pemrograman *python* dengan menggunakan tools Google Collab. Sistem dari model yang dihasilkan ini diharapkan dapat membantu dalam pengenalan pola tulisan tangan bahasa aksara Lota Ende.

2. Metode Penelitian

Pada tugas akhir ini terdapat beberapa tahapan dalam mengenali pola citra aksara lota Ende menggunakan convolutional neural network (CNN). Gambar 1 menunjukkan tahapan-tahapan penelitian yang dilakukan dan deskripsi dari masing-masing tahapan .

A. Tahapan Penelitian

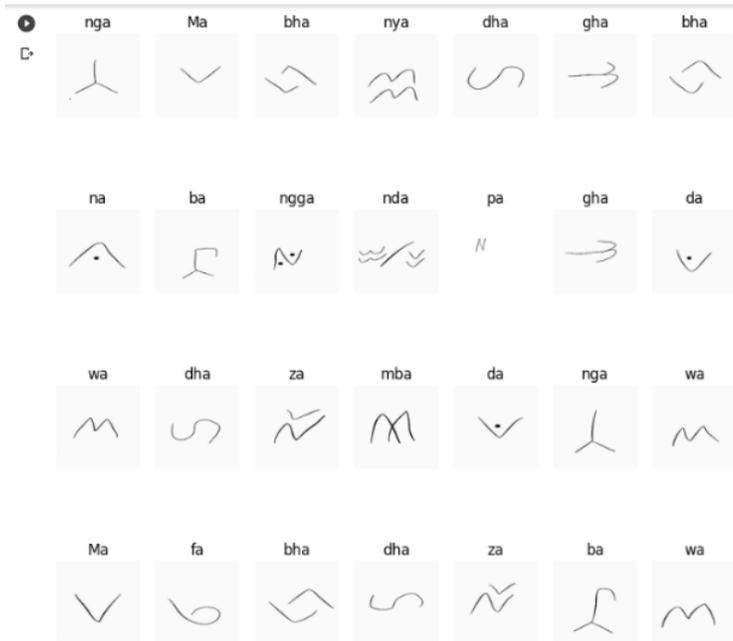


Gambar 1. Tahapan Penelitian

B. Data Colecction

Proses mengumpulkan, mengukur, dan menganalisis berbagai jenis informasi dengan menggunakan teknik standar adalah Data Collection. Tujuan utama pengumpulan data adalah untuk mengumpulkan sebanyak mungkin informasi dan data yang andal dan menganalisisnya untuk membuat keputusan bisnis yang penting [13]. Tahapan pertama yang dilakukanyakni mengumpulkan data. Data yang digunakan berasal dari hasil tulisan tangan Bahasa aksara lota Ende yang diperoleh dari responden asli aksara Lote Ende. Data ini nanti akan dipindai menggunakan mesin scan dengan format gambar (png). Dalam penelitian ini banyak tulisan tangan dari responden berjumlah 20 responden.

Setiap citra tulisan angka dibedakan dengan cara diberi label sesuai dengan angka masing-masing. Citra pada dataset ini memiliki resolusi sebesar 180 x 180 piksel dan memiliki 3 kanal warna yang berarti gambar pada dataset ini memiliki warna RGB (red, green, dan blue). Sample dataset dapat dilihat pada Gambar 2. Sample Dataset



Gambar 2. Sample Dataset

C. Data Preprocessing

Preprocessing merupakan langkah sebelum proses klasifikasi ketika sumber data perlu dibersihkan, dihapus, atau diubah menjadi karakter non-alfabet dan kata-kata yang tidak diinginkan [14]. Langkah kedua adalah pengolahan data, yang berguna untuk mengubah program menjadi format yang lebih mudah dipahami oleh komputer. Informasi yang diterima adalah informasi asli, yang seringkali tidak lengkap, bertentangan dan mengandung banyak kesalahan. Untuk mengatasi permasalahan tersebut dilakukan pengolahan data.

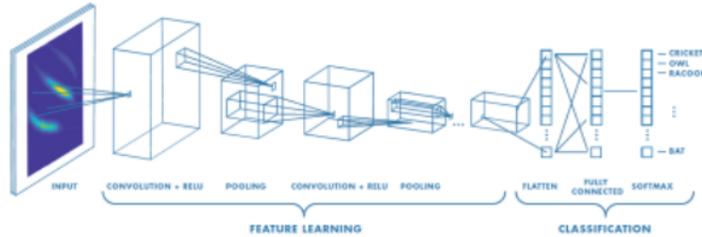
Dalam *preprocessing* dilakukan langkah pertama yakni penerapan image augmentation. Hal ini diterapkan berdasarkan data gambar yang telah ditampilkan sebelumnya. Image augmentation yang dilakukan di sini menggunakan *layer Random Flip*, *Random Rotation*, *Random Zoom* pada citra data. Hal ini bertujuan untuk mencegah *overfitting* dengan mempermainkan gambar. Langkah keempat yakni melakukan Proses *caching dataset* yang merupakan proses menyimpan data ke dalam sistem, berguna untuk mempercepat proses pelatihan. Cara kerjanya yakni data yang kita punya akan disimpan setelah itu diacak secara otomatis agar ketika di running ulang strukturnya dapat berubah.

D. Modelling CNN

Tahapan ketiga yakni *modelling* algoritma CNN. Dalam proses modelling dengan algoritma CNN, dilakukan menggunakan bantuan *software* google colab dengan bahasa pemrograman *python*. Sebelum dilakukan proses *modelling*, dataset perlu dibagi ke dalam 2 bagian yakni data training serta data testing. komposisi perbandingan yang digunakan dalam penelitian ini menggunakan rasio 80:20, dimana 80% dari total keseluruhan data akan dikategorikan sebagai data training dan 20% dari keseluruhan data akan dikategorikan sebagai data testing. Data training akan digunakan untuk melakukan proses pelatihan menggunakan algoritma CNN. sedangkan, data testing digunakan untuk melakukan proses pengujian yang nantinya akan menghasilkan hasil prediksi. Proses Modelling CNN dimulai dengan langkah satu yakni pendefinisian kelas, dilanjutkan dengan langkah kedua yakni pembuatan arsitektur model. Pembuatan arsitektur model menggunakan acuan pada metode CNN. Secara umum, arsitektur CNN terdiri dari dua bagian utama, yaitu layer ekstraksi fitur dan layer gabungan penuh. Lapisan ekstraksi fitur adalah lapisan yang digunakan untuk mengekstraksi fitur dari citra masukan.

Pada umumnya feature extraction layer memiliki dua tahap yaitu convolutional layer dan pooling. Bagian yang kedua adalah fully connected layer merupakan layer yang digunakan untuk menerima nilai dari feature layer dan mengklasifikasikan nilai tersebut pada salah satu kelas tertentu. Tahapan pada fully connected layer adalah flatten dan dense layer. Dari garis besar arsitektur yang telah disebutkan, pengguna dapat memodifikasi sedemikian rupa

sesuai dengan kebutuhan. Setelah arsitektur model dibuat, langkah ketiga yakni membuat summary model yang berguna untuk melatih data training menggunakan model yang telah dibuat. Dengan model yang telah dibuat diharapkan proses training dapat optimal dalam mengenali data sesuai label kelasnya. Langkah keempat yakni mentraining model dan menyimpan performance model ke dalam variable history dengan Epoch 100. Berikut gambar dibawah ini menunjukkan langkah-langkah algoritma CNN dalam mengolah citra masukan.



Gambar 3. Tahapan Peroses CNN [15]

E. Tahapan Performa

Tahap evaluasi performa dilakukan dengan melihat hasil akurasi yang dihasil oleh model CNN. Pengujian ini dilakukan dua tahap yaitu tahapan training dan testing. Tahap training merupakan tahapan dimana model CNN diuji dengan data latih yang sudah disediakan. Jumlah data latih yang disediakan sebanyak 700 data gambar, dengan jumlah gambar per kelas sebanyak 20 gambar dengan 28 kelas. Data training dibagi kembali menjadi dua yaitu training dan testing, yaitu sebanyak 560 training dan 140 testing. Tahap testing adalah tahap pengujian model yang telah dilakukan tahap pelatihan. Jumlah data latih dalam penelitian ini sebanyak 140 data gambar, dengan jumlah gambar per kelas sebanyak 5 gambar dengan jumlah 28 kelas. Pada tahap ini, model diuji dengan gambar yang berbeda dengan tujuan menguji apakah model sudah menghasilkan performa yang baik dalam mengenali data sesuai label kelasnya.

Klasifikasi		Aktual (Nilai sebenarnya)	
		Positive	Negative
Prediction (Nilai Prediksi)	Positive	True Positive (TP) Corect result	False Positive (FP) Unexpected result
	Negative	False Negative (FN) Missing result	True Negative (TN) Corect absence of result

Keterangan :

- TP : Jumlah Predeksi benar Kelas Positif
- TN : Jumlah Predeksi benar Kelas Negatif
- FP : Kelas asli negatif, dipredeksi Positif
- FN : Kelas asli Positif dipredeksi Negatif

Klasifikasi membutuhkan perhitungan data matriks dengan menggunakan empat pengukuran, yaitu true positive (TP), true negative (TN), false positive (FP) dan false negative (FN) untuk mewakili hasil dari classifier yang ada. Pada tahap evaluasi, akan menampilkan nilai akurasi, Precision recall dan f1-score.

1. Akurasi

Matriks yang menunjukkan berapa banyak kelas yang diprediksi model dengan benar dan cerdas. Ini adalah model yang paling umum digunakan, tetapi rentan terhadap salah tafsir

keefektifan (bias) ketika data tidak seimbang. Persamaan untuk matriks itu sendiri adalah sebagai berikut :

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Gambar 4. Mengukur Akurasi

2. Precision

Berukuran seberapa seberapa akurat model kelas positif memprediksi hal yang sama dengan kelas positif (aktual). Tetapi, metrik ini tidak dapat mengungkapkan berapa banyak (sebenarnya) kelas positif yang mempunyai prediksi akurat benar. Rumus matematika metrik ini adalah menjadi berikut :

$$Precision = \frac{TP}{TP + FP}$$

Gambar 5. Mengukur Presisi

3. Recall

Matriks yg menampilkan seberapa baik kelas positif (sebenarnya) diprediksi sebagai kelas positif. Namun, matriks ini tidak bisa mendeskripsikan seberapa baik contoh memprediksi kelas positif menjadi kelas positif (nyata). Persamaan buat metrik ini sendiri adalah :

$$Recall = \frac{TP}{TP + FN}$$

Gambar 6. Mengukur Recall

4. F-1 Score

Matriks tersebut memasukkan kesenjangan presisi dan recall dalam evaluasi kinerja kategori positif dengan mencari tahu rata-rata harmonik dari keduanya. Skor F1, bagaimanapun pula tidak bisa secara eksplisit mengidentifikasi peringkat kinerja yang buruk karena dua berukuran sebelumnya terbatas di klasifikasi positif. Tetapi dengan menggunakan berbobot yang memperhitungkan kelas sertadistribusinya, semua dilemma ini teratasi:

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

Gambar 7. Mengukur F1-Score

3. Hasil dan Pembahasan

Dalam proses *modelling* menggunakan Bahasa pemrograman *python*. Data training dilatih menggunakan arsitektur model desain CNN. Setelah terbentuk model, langkah selanjutnya yaitu melakukan *training* citra data maka kedalam model dengan fit model. Dalam melakukan fit model digunakan epoch = 100, batch_size = 32 dan validation split = 0,2. Epoch berarti berapa kali jaringan akan melihat seluruh kumpulan data, sedangkan batch_size merupakan jumlah contoh pelatihan dalam satu forward/backward pass. Semakin tinggi nilai batch_size maka akan semakin banyak memori yang dibutuhkan. langkah selanjutnya tahap training dilakukan karena proses training

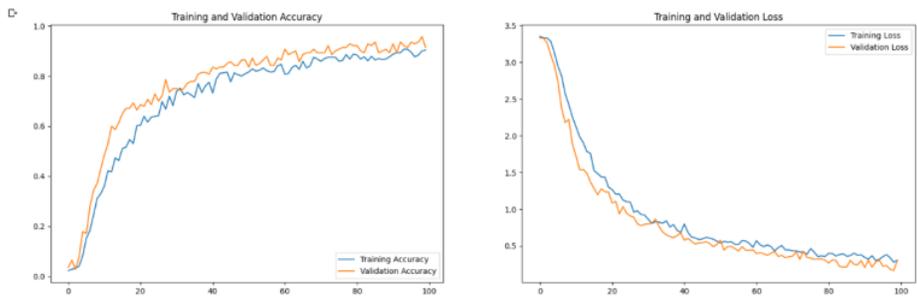
merupakan proses pembelajaran mesin kemudian dapat dilakukan dan dapat menjadi metode yang telah ditentukan mengingat model setiap kelas dalam data training. Proses training ditunjukkan pada gambar 7.

```
# Mentraining Model dan menyimpan performance model ke dalam variable history
epochs=100
history = model.fit( # ( hasil akhir)
    train_ds,
    validation_data=test_ds,
    epochs=epochs # Percobaan
)
```

```
Epoch 0/100: 47s 24/7500 - loss: 3.3468 - accuracy: 0.0000 - val_loss: 3.2039 - val_accuracy: 0.0000
Epoch 1/100: 31s 24/7500 - loss: 3.3558 - accuracy: 0.0000 - val_loss: 3.2034 - val_accuracy: 0.0000
Epoch 2/100: 31s 24/7500 - loss: 3.3534 - accuracy: 0.0000 - val_loss: 3.2093 - val_accuracy: 0.0000
Epoch 3/100: 31s 24/7500 - loss: 3.3508 - accuracy: 0.0000 - val_loss: 3.2078 - val_accuracy: 0.0000
Epoch 4/100: 31s 24/7500 - loss: 3.3476 - accuracy: 0.0000 - val_loss: 3.2038 - val_accuracy: 0.0000
Epoch 5/100: 31s 24/7500 - loss: 3.3438 - accuracy: 0.0000 - val_loss: 3.2004 - val_accuracy: 0.0000
Epoch 6/100: 31s 24/7500 - loss: 3.3398 - accuracy: 0.0000 - val_loss: 3.1964 - val_accuracy: 0.0000
Epoch 7/100: 31s 24/7500 - loss: 3.3356 - accuracy: 0.0000 - val_loss: 3.1920 - val_accuracy: 0.0000
Epoch 8/100: 31s 24/7500 - loss: 3.3312 - accuracy: 0.0000 - val_loss: 3.1872 - val_accuracy: 0.0000
Epoch 9/100: 31s 24/7500 - loss: 3.3266 - accuracy: 0.0000 - val_loss: 3.1820 - val_accuracy: 0.0000
Epoch 10/100: 31s 24/7500 - loss: 3.3218 - accuracy: 0.0000 - val_loss: 3.1764 - val_accuracy: 0.0000
Epoch 11/100: 31s 24/7500 - loss: 3.3168 - accuracy: 0.0000 - val_loss: 3.1704 - val_accuracy: 0.0000
Epoch 12/100: 31s 24/7500 - loss: 3.3116 - accuracy: 0.0000 - val_loss: 3.1640 - val_accuracy: 0.0000
Epoch 13/100: 31s 24/7500 - loss: 3.3062 - accuracy: 0.0000 - val_loss: 3.1572 - val_accuracy: 0.0000
Epoch 14/100: 31s 24/7500 - loss: 3.3006 - accuracy: 0.0000 - val_loss: 3.1500 - val_accuracy: 0.0000
Epoch 15/100: 31s 24/7500 - loss: 3.2948 - accuracy: 0.0000 - val_loss: 3.1424 - val_accuracy: 0.0000
Epoch 16/100: 31s 24/7500 - loss: 3.2888 - accuracy: 0.0000 - val_loss: 3.1344 - val_accuracy: 0.0000
Epoch 17/100: 31s 24/7500 - loss: 3.2826 - accuracy: 0.0000 - val_loss: 3.1260 - val_accuracy: 0.0000
Epoch 18/100: 31s 24/7500 - loss: 3.2762 - accuracy: 0.0000 - val_loss: 3.1172 - val_accuracy: 0.0000
Epoch 19/100: 31s 24/7500 - loss: 3.2696 - accuracy: 0.0000 - val_loss: 3.1080 - val_accuracy: 0.0000
Epoch 20/100: 31s 24/7500 - loss: 3.2628 - accuracy: 0.0000 - val_loss: 3.0984 - val_accuracy: 0.0000
Epoch 21/100: 31s 24/7500 - loss: 3.2558 - accuracy: 0.0000 - val_loss: 3.0884 - val_accuracy: 0.0000
Epoch 22/100: 31s 24/7500 - loss: 3.2486 - accuracy: 0.0000 - val_loss: 3.0780 - val_accuracy: 0.0000
Epoch 23/100: 31s 24/7500 - loss: 3.2412 - accuracy: 0.0000 - val_loss: 3.0672 - val_accuracy: 0.0000
Epoch 24/100: 31s 24/7500 - loss: 3.2336 - accuracy: 0.0000 - val_loss: 3.0560 - val_accuracy: 0.0000
Epoch 25/100: 31s 24/7500 - loss: 3.2258 - accuracy: 0.0000 - val_loss: 3.0444 - val_accuracy: 0.0000
Epoch 26/100: 31s 24/7500 - loss: 3.2178 - accuracy: 0.0000 - val_loss: 3.0324 - val_accuracy: 0.0000
Epoch 27/100: 31s 24/7500 - loss: 3.2096 - accuracy: 0.0000 - val_loss: 3.0200 - val_accuracy: 0.0000
Epoch 28/100: 31s 24/7500 - loss: 3.2012 - accuracy: 0.0000 - val_loss: 3.0072 - val_accuracy: 0.0000
Epoch 29/100: 31s 24/7500 - loss: 3.1926 - accuracy: 0.0000 - val_loss: 2.9940 - val_accuracy: 0.0000
Epoch 30/100: 31s 24/7500 - loss: 3.1838 - accuracy: 0.0000 - val_loss: 2.9804 - val_accuracy: 0.0000
Epoch 31/100: 31s 24/7500 - loss: 3.1748 - accuracy: 0.0000 - val_loss: 2.9664 - val_accuracy: 0.0000
Epoch 32/100: 31s 24/7500 - loss: 3.1656 - accuracy: 0.0000 - val_loss: 2.9520 - val_accuracy: 0.0000
Epoch 33/100: 31s 24/7500 - loss: 3.1562 - accuracy: 0.0000 - val_loss: 2.9372 - val_accuracy: 0.0000
Epoch 34/100: 31s 24/7500 - loss: 3.1466 - accuracy: 0.0000 - val_loss: 2.9220 - val_accuracy: 0.0000
Epoch 35/100: 31s 24/7500 - loss: 3.1368 - accuracy: 0.0000 - val_loss: 2.9064 - val_accuracy: 0.0000
Epoch 36/100: 31s 24/7500 - loss: 3.1268 - accuracy: 0.0000 - val_loss: 2.8904 - val_accuracy: 0.0000
Epoch 37/100: 31s 24/7500 - loss: 3.1166 - accuracy: 0.0000 - val_loss: 2.8740 - val_accuracy: 0.0000
Epoch 38/100: 31s 24/7500 - loss: 3.1062 - accuracy: 0.0000 - val_loss: 2.8572 - val_accuracy: 0.0000
Epoch 39/100: 31s 24/7500 - loss: 3.0956 - accuracy: 0.0000 - val_loss: 2.8400 - val_accuracy: 0.0000
Epoch 40/100: 31s 24/7500 - loss: 3.0848 - accuracy: 0.0000 - val_loss: 2.8224 - val_accuracy: 0.0000
Epoch 41/100: 31s 24/7500 - loss: 3.0738 - accuracy: 0.0000 - val_loss: 2.8052 - val_accuracy: 0.0000
Epoch 42/100: 31s 24/7500 - loss: 3.0626 - accuracy: 0.0000 - val_loss: 2.7876 - val_accuracy: 0.0000
Epoch 43/100: 31s 24/7500 - loss: 3.0512 - accuracy: 0.0000 - val_loss: 2.7700 - val_accuracy: 0.0000
Epoch 44/100: 31s 24/7500 - loss: 3.0396 - accuracy: 0.0000 - val_loss: 2.7520 - val_accuracy: 0.0000
Epoch 45/100: 31s 24/7500 - loss: 3.0278 - accuracy: 0.0000 - val_loss: 2.7336 - val_accuracy: 0.0000
Epoch 46/100: 31s 24/7500 - loss: 3.0158 - accuracy: 0.0000 - val_loss: 2.7148 - val_accuracy: 0.0000
Epoch 47/100: 31s 24/7500 - loss: 3.0036 - accuracy: 0.0000 - val_loss: 2.6956 - val_accuracy: 0.0000
Epoch 48/100: 31s 24/7500 - loss: 2.9912 - accuracy: 0.0000 - val_loss: 2.6760 - val_accuracy: 0.0000
Epoch 49/100: 31s 24/7500 - loss: 2.9786 - accuracy: 0.0000 - val_loss: 2.6560 - val_accuracy: 0.0000
Epoch 50/100: 31s 24/7500 - loss: 2.9658 - accuracy: 0.0000 - val_loss: 2.6356 - val_accuracy: 0.0000
Epoch 51/100: 31s 24/7500 - loss: 2.9528 - accuracy: 0.0000 - val_loss: 2.6148 - val_accuracy: 0.0000
Epoch 52/100: 31s 24/7500 - loss: 2.9396 - accuracy: 0.0000 - val_loss: 2.5936 - val_accuracy: 0.0000
Epoch 53/100: 31s 24/7500 - loss: 2.9262 - accuracy: 0.0000 - val_loss: 2.5720 - val_accuracy: 0.0000
Epoch 54/100: 31s 24/7500 - loss: 2.9126 - accuracy: 0.0000 - val_loss: 2.5500 - val_accuracy: 0.0000
Epoch 55/100: 31s 24/7500 - loss: 2.8988 - accuracy: 0.0000 - val_loss: 2.5276 - val_accuracy: 0.0000
Epoch 56/100: 31s 24/7500 - loss: 2.8848 - accuracy: 0.0000 - val_loss: 2.5048 - val_accuracy: 0.0000
Epoch 57/100: 31s 24/7500 - loss: 2.8706 - accuracy: 0.0000 - val_loss: 2.4816 - val_accuracy: 0.0000
Epoch 58/100: 31s 24/7500 - loss: 2.8562 - accuracy: 0.0000 - val_loss: 2.4580 - val_accuracy: 0.0000
Epoch 59/100: 31s 24/7500 - loss: 2.8416 - accuracy: 0.0000 - val_loss: 2.4340 - val_accuracy: 0.0000
Epoch 60/100: 31s 24/7500 - loss: 2.8268 - accuracy: 0.0000 - val_loss: 2.4096 - val_accuracy: 0.0000
Epoch 61/100: 31s 24/7500 - loss: 2.8118 - accuracy: 0.0000 - val_loss: 2.3848 - val_accuracy: 0.0000
Epoch 62/100: 31s 24/7500 - loss: 2.7966 - accuracy: 0.0000 - val_loss: 2.3596 - val_accuracy: 0.0000
Epoch 63/100: 31s 24/7500 - loss: 2.7812 - accuracy: 0.0000 - val_loss: 2.3340 - val_accuracy: 0.0000
Epoch 64/100: 31s 24/7500 - loss: 2.7656 - accuracy: 0.0000 - val_loss: 2.3080 - val_accuracy: 0.0000
Epoch 65/100: 31s 24/7500 - loss: 2.7498 - accuracy: 0.0000 - val_loss: 2.2816 - val_accuracy: 0.0000
Epoch 66/100: 31s 24/7500 - loss: 2.7338 - accuracy: 0.0000 - val_loss: 2.2548 - val_accuracy: 0.0000
Epoch 67/100: 31s 24/7500 - loss: 2.7176 - accuracy: 0.0000 - val_loss: 2.2276 - val_accuracy: 0.0000
Epoch 68/100: 31s 24/7500 - loss: 2.7012 - accuracy: 0.0000 - val_loss: 2.2000 - val_accuracy: 0.0000
Epoch 69/100: 31s 24/7500 - loss: 2.6846 - accuracy: 0.0000 - val_loss: 2.1720 - val_accuracy: 0.0000
Epoch 70/100: 31s 24/7500 - loss: 2.6678 - accuracy: 0.0000 - val_loss: 2.1436 - val_accuracy: 0.0000
Epoch 71/100: 31s 24/7500 - loss: 2.6508 - accuracy: 0.0000 - val_loss: 2.1148 - val_accuracy: 0.0000
Epoch 72/100: 31s 24/7500 - loss: 2.6336 - accuracy: 0.0000 - val_loss: 2.0856 - val_accuracy: 0.0000
Epoch 73/100: 31s 24/7500 - loss: 2.6162 - accuracy: 0.0000 - val_loss: 2.0560 - val_accuracy: 0.0000
Epoch 74/100: 31s 24/7500 - loss: 2.5986 - accuracy: 0.0000 - val_loss: 2.0260 - val_accuracy: 0.0000
Epoch 75/100: 31s 24/7500 - loss: 2.5808 - accuracy: 0.0000 - val_loss: 1.9956 - val_accuracy: 0.0000
Epoch 76/100: 31s 24/7500 - loss: 2.5628 - accuracy: 0.0000 - val_loss: 1.9648 - val_accuracy: 0.0000
Epoch 77/100: 31s 24/7500 - loss: 2.5446 - accuracy: 0.0000 - val_loss: 1.9336 - val_accuracy: 0.0000
Epoch 78/100: 31s 24/7500 - loss: 2.5262 - accuracy: 0.0000 - val_loss: 1.9020 - val_accuracy: 0.0000
Epoch 79/100: 31s 24/7500 - loss: 2.5076 - accuracy: 0.0000 - val_loss: 1.8700 - val_accuracy: 0.0000
Epoch 80/100: 31s 24/7500 - loss: 2.4888 - accuracy: 0.0000 - val_loss: 1.8376 - val_accuracy: 0.0000
Epoch 81/100: 31s 24/7500 - loss: 2.4698 - accuracy: 0.0000 - val_loss: 1.8048 - val_accuracy: 0.0000
Epoch 82/100: 31s 24/7500 - loss: 2.4506 - accuracy: 0.0000 - val_loss: 1.7716 - val_accuracy: 0.0000
Epoch 83/100: 31s 24/7500 - loss: 2.4312 - accuracy: 0.0000 - val_loss: 1.7380 - val_accuracy: 0.0000
Epoch 84/100: 31s 24/7500 - loss: 2.4116 - accuracy: 0.0000 - val_loss: 1.7040 - val_accuracy: 0.0000
Epoch 85/100: 31s 24/7500 - loss: 2.3918 - accuracy: 0.0000 - val_loss: 1.6696 - val_accuracy: 0.0000
Epoch 86/100: 31s 24/7500 - loss: 2.3718 - accuracy: 0.0000 - val_loss: 1.6348 - val_accuracy: 0.0000
Epoch 87/100: 31s 24/7500 - loss: 2.3516 - accuracy: 0.0000 - val_loss: 1.5996 - val_accuracy: 0.0000
Epoch 88/100: 31s 24/7500 - loss: 2.3312 - accuracy: 0.0000 - val_loss: 1.5640 - val_accuracy: 0.0000
Epoch 89/100: 31s 24/7500 - loss: 2.3106 - accuracy: 0.0000 - val_loss: 1.5280 - val_accuracy: 0.0000
Epoch 90/100: 31s 24/7500 - loss: 2.2898 - accuracy: 0.0000 - val_loss: 1.4916 - val_accuracy: 0.0000
Epoch 91/100: 31s 24/7500 - loss: 2.2688 - accuracy: 0.0000 - val_loss: 1.4548 - val_accuracy: 0.0000
Epoch 92/100: 31s 24/7500 - loss: 2.2476 - accuracy: 0.0000 - val_loss: 1.4176 - val_accuracy: 0.0000
Epoch 93/100: 31s 24/7500 - loss: 2.2262 - accuracy: 0.0000 - val_loss: 1.3800 - val_accuracy: 0.0000
Epoch 94/100: 31s 24/7500 - loss: 2.2046 - accuracy: 0.0000 - val_loss: 1.3420 - val_accuracy: 0.0000
Epoch 95/100: 31s 24/7500 - loss: 2.1828 - accuracy: 0.0000 - val_loss: 1.3036 - val_accuracy: 0.0000
Epoch 96/100: 31s 24/7500 - loss: 2.1608 - accuracy: 0.0000 - val_loss: 1.2648 - val_accuracy: 0.0000
Epoch 97/100: 31s 24/7500 - loss: 2.1386 - accuracy: 0.0000 - val_loss: 1.2256 - val_accuracy: 0.0000
Epoch 98/100: 31s 24/7500 - loss: 2.1162 - accuracy: 0.0000 - val_loss: 1.1860 - val_accuracy: 0.0000
Epoch 99/100: 31s 24/7500 - loss: 2.0936 - accuracy: 0.0000 - val_loss: 1.1460 - val_accuracy: 0.0000
Epoch 100/100: 31s 24/7500 - loss: 2.0708 - accuracy: 0.0000 - val_loss: 1.1056 - val_accuracy: 0.0000
```

Gambar 8. Proses Training

Gambar 8 dan Gambar 9 akan menunjukkan hasil dari penerapan algoritma CNN. gambar 8. Menunjukkan bahwa untuk akurasi data training terjadi peningkatan akurasi secara signifikan pada iterasi 0 sampai dengan iterasi ke - 40 dan pada iterasi lebih dari 60 cenderung naik disatu titik. Untuk akurasi validasi data testing, terjadi peningkatan akurasi secara signifikan pada iterasi 0 sampai dengan iterasi ke- 60 dan pada iterasi lebih dari 40 tidak terjadi perubahan yang signifikan terhadap tingkat akurasi.



Gambar 9. Grafik Model akurasi berdasarkan Epoch 100

Berdasarkan Gambar 8 dapat diketahui bahwa grafik akurasi training semakin meningkat seiring dengan bertambahnya jumlah epoch. Akurasi yang diperoleh pada iterasi ke-100 adalah 96.88% pada training, dan 100% pada validasi data testing. Waktu yang dibutuhkan dalam menjalankan training 100 epoch adalah 50 menit. Banyaknya epoch mempengaruhi waktu training, semakin banyak jumlah epoch maka semakin lama waktu training. Penurunan grafik los ini merupakan hal baik karena nilai loss yang dihasilkan semakin kecil. Model yang dihasilkan sudah baik karena memiliki loss dan accuracy sebesar 0.9536 cross entropy loss dan 0.0113 validasi loss. Model dianggap baik apabila memiliki akurasi yang tinggi dan loss yang kecil. Banyaknya jumlah epoch dapat meningkatkan akurasi. Akan tetapi, terlalu banyak jumlah epoch dapat menyebabkan overfitting, yaitu pada saat training system terlalu terpaku pada data training sehingga akurasi training sangat besar dan akurasi testing menjadi kecil. System yang baik adalah system yang akurasi training dan testing memiliki akurasi yang tinggi dan saling mendekati.

1/1 [=====] - 0s 32ms/step
This image most likely belongs to za with a 100.00 percent confidence.



12

4. Kesimpulan

Kesimpulan yang didapatkan pada penelitian ini yakni model yang dihasilkan mampu mengenali tulisan tangan angka serta mampu melakukan analisis performa terhadap pengenalan tulisan tangan angka dengan cukup baik berdasarkan perubahan jumlah iterasi dengan menggunakan algoritma CNN. Berdasarkan pengujian yang telah dilakukan, diperoleh kesimpulan bahwa performa neural network dipengaruhi oleh jumlah iterasi. Performa akurasi meningkat pada iterasi ke-0 sampai dengan iterasi ke-20, akan tetapi untuk iterasi ke-40 sampai dengan iterasi ke-100 tidak mengalami perubahan yang cukup signifikan, akurasi dalam rentang iterasi 40-100 cukup stabil berada pada satu titik. Hasil evaluasi pengukuran kinerja untuk menguji tingkat keberhasilan model dalam pengenalan tulisan tangan angka sehingga didapat akurasi sebesar 100%. Adapun saran untuk penelitian selanjutnya diharapkan dapat menggunakan komposisi Epoch selain 100, serta dapat menggunakan algoritma untuk pengenalan image selain CNN. Untuk mendapatkan kinerja model yang lebih baik dapat menggunakan model pengembangan dari convolutional neural network seperti transfer learning atau recurrent neural network untuk memperoleh keakuratan hasil yang lebih optimal.

Ucapan Terimakasih

Ucapan terimakasih disampaikan kepada Universitas Muhammadiyah Sidoarjo yang telah memberikan fasilitas dalam menyelesaikan penelitian.

Daftar Pustaka

- [1] Wakhyuninggarsih, "Mengenali Aksara Lota Dari Kabupaten Ende," *Indonesiana*, 2020. <https://kebudayaan.kemdikbud.go.id/bpnbbali/mengenali-aksara-lota-dari-kabupaten-ende/> (accessed Dec. 07, 2022).
- [2] E. Alfian and A. Brahma, "Perancangan Typeface Aksara Lota Ende," vol. 3, pp. 96–101, 2018.
- [3] D. A. Ofori *et al.*, "PENGENALAN AKSARA LOTE ENDE MELALUI CITRA DIGITAL MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK TUGAS," *Molecules*, vol. 2, no. 1, pp. 1–12, 2020, [Online]. Available: <http://clik.dva.gov.au/rehabilitation-library/1-introduction-rehabilitation%0Ahttp://www.scirp.org/journal/doi.aspx?DOI=10.4236/as.2017.81005%0Ahttp://www.scirp.org/journal/PaperDownload.aspx?DOI=10.4236/as.2012.34066%0Ahttp://dx.doi.org/10.1016/j.pbi.201>
- [4] I. D. A. N. Pengujian, "UNIKOM_Alwan H_Bab 4," *Tahapan Penguji. Sist.*, pp. 99–125, 2017.
- [5] D. Fitriati, "PERBANDINGAN KINERJA CNN LeNet 5 DAN EXTREME LEARNING MACHINE PADA PENGENALAN CITRA TULISAN TANGAN ANGKA," *J. Teknol. Terpadu*, vol. 2, no. 1, 2016, doi: 10.54914/jtt.v2i1.45.
- [6] R. Setiawan, "Mengenali Deep Learning Lebih Jelas", [Online]. Available: <https://www.dicoding.com/blog/mengenali-deep-learning/>
- [7] Z. F. Abror, "Klasifikasi Citra Kebakaran Dan Non Kebakaran," *J. Ilm. Teknol. dan Rekayasa*, vol. 24, no.

- 100, pp. 102–113, 2019.
- [8] I. W. Suartika E. P, “Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101,” *J. Tek. ITS*, vol. 5, no. 1, p. 76, 2016, [Online]. Available: <http://repository.its.ac.id/48842/>
- [9] C. Kozyrkov, “Tensorflow Adalah Framework Machine Learning yang Kuat,” 2018. <https://kozyrk.medium.com/indonesian-9-things-b0524ccb9d7c> (accessed Dec. 07, 2022).
- [10] dkk 2018) richard oliver (dalam Zeithml., “*濟無*No Title No Title No Title,” *Angew. Chemie Int. Ed.* 6(11), 951–952., pp. 2013–2015, 2021.
- [11] S. Mawaddah and N. Suciati, “Pengenalan Karakter Tulisan Tangan Menggunakan Ekstraksi Fitur Bentuk Berbasis Chain Code,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 4, p. 683, 2020, doi: 10.25126/jtiik.2020742022.
- [12] A. Willyanto, D. Alamsyah, and H. Irsyad, “Identifikasi Tulisan Tangan Aksara Jepang Hiragana Menggunakan Metode CNN Arsitektur VGG-16,” *J. Algorit.*, vol. 2, no. 1, pp. 1–11, 2021.
- [13] Building, “Data Collection untuk Analisis,” 21 maret 2022, 2022. <https://algorit.ma/blog/data-collection-2022/>
- [14] F. A. Muttaqin and A. M. Bachtiar, “Implementasi Teks Mining Pada Aplikasi Pengawasan Penggunaan Internet Anak ‘Dodo Kids Browser,’” *J. Ilm. Komput. dan Inform.*, pp. 1–8, 2016.
- [15] Sutha, “Softmax CNN,” *J. Chem. Inf. Model.*, vol. 53, no. 9, pp. 1689–1699, 2018.

ROFINUS ARYANTO

ORIGINALITY REPORT

25%

SIMILARITY INDEX

23%

INTERNET SOURCES

5%

PUBLICATIONS

12%

STUDENT PAPERS

PRIMARY SOURCES

1	Submitted to Konsorsium 4 Perguruan Tinggi Swasta Student Paper	3%
2	ejournal.gunadarma.ac.id Internet Source	3%
3	dspace.uii.ac.id Internet Source	3%
4	medium.com Internet Source	3%
5	123dok.com Internet Source	2%
6	www.researchgate.net Internet Source	1%
7	adoc.pub Internet Source	1%
8	media.neliti.com Internet Source	1%
9	conference.binadarma.ac.id Internet Source	1%

10	id.123dok.com Internet Source	1 %
11	ditsmp.kemdikbud.go.id Internet Source	1 %
12	repository.mercubuana.ac.id Internet Source	1 %
13	Submitted to Universitas Putera Indonesia YPTK Padang Student Paper	1 %
14	ejournal.bsi.ac.id Internet Source	1 %
15	jtiik.ub.ac.id Internet Source	1 %
16	elibrary.unikom.ac.id Internet Source	1 %
17	ejournal.upm.ac.id Internet Source	1 %

Exclude quotes On

Exclude matches < 1%

Exclude bibliography On