

Penerapan *Semi-Supervised Learning* Menggunakan Teknik *Pseudo-labeling* Pada CNN Untuk Pengenalan Aksara Lontara

Indah Lestari¹, Ramlia Ramadani Sudin², Rayhan Permana Putra³, Adha Mashur Sajiah⁴

^{1,2,3,4}Jurusan Teknik Informatika, Fakultas Teknik, Universitas Halu Oleo, Kendari, Indonesia

surel: ¹indahlestari_e1e123004@student.uho.ac.id, ²ramadaniramalia@gmail.com, ³rehanpermana2311@gmail.com,

⁴adha.m.sajiah@uho.ac.id

Info Artikel

Sejarah artikel:

Diterima 06-07-2026

Revisi 08-08-2026

Diterima 12-08-2026

Kata kunci:

Aksara lontara

Convolutional neural network

Deep learning

Pengenalan pola

Pseudo-labeling

ABSTRAK

Aksara Lontara merupakan representasi kultural masyarakat Sulawesi Selatan yang memerlukan upaya preservasi digital secara berkelanjutan. *Convolutional Neural Network* (CNN) telah banyak digunakan untuk pengenalan citra karakter aksara daerah, namun performanya sangat bergantung pada ketersediaan data berlabel (*labeled data*) yang umumnya terbatas dan mahal secara anotasi. Penelitian ini menerapkan *Semi-Supervised Learning* (SSL) dengan teknik *Pseudo-labeling* pada arsitektur CNN untuk mengklasifikasikan 23 kelas aksara Lontara. Dataset yang digunakan berjumlah 7.452 citra yang diperoleh dari repositori publik Kaggle, kemudian dibagi menjadi 1.491 citra data uji (20%), 2.384 citra data berlabel (40% dari sisa data), dan 3.577 citra data tidak berlabel (60% dari sisa data). Arsitektur CNN yang diusulkan terdiri atas tiga blok konvolusi dengan lapisan *Batch Normalization*, *Max Pooling*, satu lapisan *Dense 256 neuron*, dan *Dropout 0.5*, dengan total 1.279.959 parameter. Model dasar yang dilatih hanya dengan 2.384 citra berlabel mencapai akurasi pengujian sebesar 99.93%. Selanjutnya, model memprediksi 3.577 citra tidak berlabel, dan prediksi dengan probabilitas di atas ambang batas (*confidence threshold*) $\tau = 0.95$ dikonversi menjadi *pseudo-label*, menghasilkan 3.537 citra tambahan (98,88% dari total data tidak berlabel). Penggabungan data berlabel dan *pseudo-labeled* menjadi 5.921 citra digunakan untuk melatih ulang model secara iteratif, sehingga akurasi pengujian akhir meningkat menjadi 100%. Temuan ini menunjukkan bahwa kombinasi regularisasi (augmentasi, *Batch Normalization*, *Dropout*) dan SSL berbasis *pseudo-labeling* sangat efektif untuk pengenalan citra aksara Lontara meskipun hanya menggunakan sebagian kecil data beranotasi manual.

Penulis yang sesuai:

Indah Lestari

Program Studi Teknik Informatika Fakultas Teknik Universitas Halu Oleo

Email: indahlestari_e1e123004@student.uho.ac.id



1. PENDAHULUAN

Aksara merupakan salah satu unsur kebudayaan yang keberadaannya perlu terus dijaga dan dilestarikan. Masyarakat Sulawesi Selatan memiliki aksara tradisional yang disebut aksara Lontara, yang secara historis digunakan untuk menuliskan berbagai dokumen dalam bahasa Bugis dan Makassar. Sebagaimana aksara daerah lain seperti aksara Lampung [1], aksara Jawa [2], dan aksara Sunda [3], aksara Lontara tersusun dari sekumpulan bentuk goresan yang melambangkan fonem atau suku kata dasar. Penggunaan aksara Lontara saat ini membutuhkan perhatian khusus karena frekuensi pemakaiannya yang terus menurun, sehingga banyak individu mengalami kesulitan ketika harus mengidentifikasi maupun membaca dokumen-dokumen yang ditulis dengan aksara tersebut.

Berbagai upaya pengenalan pola aksara daerah telah dilakukan oleh peneliti sebelumnya, baik pada aksara Lota Ende [4] maupun aksara Lontara itu sendiri [5]. Pendekatan *Convolutional Neural Network* (CNN) banyak dipilih karena memiliki lapisan konvolusi dan *pooling* yang memungkinkan ekstraksi fitur spasial bekerja secara otomatis tanpa rekayasa fitur manual [6]. Penelitian pengenalan huruf aksara Lontara berbasis CNN yang dilakukan pada citra cetak maupun tulisan tangan telah berhasil mencapai akurasi yang cukup baik, namun performanya tetap bergantung pada jumlah dan keragaman data latih yang tersedia [7]. Pada arsitektur CNN yang lebih dalam, penambahan lapisan *Batch Normalization* pada setiap blok konvolusi turut berkontribusi menstabilkan proses pelatihan dan mempercepat konvergensi [8].


Permasalahan utama yang muncul pada pengenalan citra aksara daerah adalah terbatasnya korpus data berlabel (*labeled data*). Proses anotasi citra aksara secara manual oleh tenaga pakar membutuhkan alokasi sumber daya dan waktu yang besar. Sebaliknya, akuisisi citra aksara yang belum teranotasi (*unlabeled data*) relatif lebih mudah diperoleh, baik dari pemindaian manuskrip maupun repositori data terbuka. Oleh karena itu, *Semi-Supervised Learning* (SSL) digunakan karena merupakan paradigma yang mengakomodasi pelatihan model dengan proporsi kecil data berlabel dan proporsi besar data tidak berlabel. Dari berbagai varian SSL, *Pseudo-labeling* dipilih sebagai pendekatan optimasi pada arsitektur CNN yang diajukan. Teknik ini pertama kali diperkenalkan sebagai metode sederhana dan efisien untuk jaringan saraf dalam (*deep neural network*) [9], yang beroperasi dengan mengeksekusi model dasar (*baseline*) hasil pelatihan pada data berlabel untuk menginferensi probabilitas kelas pada data tidak berlabel. Probabilitas yang melampaui ambang batas kepercayaan (*confidence threshold*) tertentu dikonversi menjadi label aktual untuk mengkalibrasi ulang bobot model pada tahap pelatihan selanjutnya.

Pendekatan *Pseudo-labeling* telah dibuktikan efektif pada berbagai domain citra di Indonesia, salah satunya pada klasifikasi pola Batik yang berhasil meningkatkan akurasi model meskipun hanya menggunakan sebagian kecil data beranotasi [10]. Pada sisi lain, untuk dataset citra yang relatif terbatas, teknik augmentasi data seperti rotasi, pergeseran, dan distorsi geometri ringan juga terbukti membantu CNN menggeneralisasi fitur visual dengan lebih baik dan menekan risiko *overfitting* [11]. Kombinasi strategi regularisasi tersebut menjadi dasar pertimbangan dalam merancang arsitektur pada penelitian ini, mengingat jumlah data aksara Lontara berlabel yang tersedia relatif terbatas dibandingkan kebutuhan pelatihan CNN secara konvensional.

Berdasarkan permasalahan tersebut, penelitian ini mengajukan arsitektur CNN termodifikasi dengan integrasi strategi *Semi-Supervised Learning* berbasis *Pseudo-labeling* untuk memfasilitasi pengenalan citra aksara Lontara. Target dari penelitian ini adalah mengevaluasi komparasi kinerja klasifikasi antara pendekatan *supervised* konvensional yang hanya memanfaatkan sebagian kecil data berlabel, dengan pendekatan *semi-supervised pseudo-labeling* yang turut memanfaatkan data tidak berlabel berjumlah jauh lebih besar. Evaluasi model didasarkan pada metrik pengujian standar yang umum digunakan dalam studi klasifikasi citra [12]. Alur penelitian secara keseluruhan, mulai dari pengumpulan data hingga evaluasi akhir, dirancang secara sistematis untuk memberikan hasil yang optimal.

2. METODE


Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan menerapkan *Semi-Supervised Learning* berbasis *Pseudo-labeling* pada model CNN untuk pengenalan aksara Lontara. Penelitian dirancang dalam beberapa tahap utama: pengumpulan dan analisis dataset, *preprocessing*, pembangunan model CNN, pelatihan awal, penerapan *pseudo-labeling*, dan evaluasi akhir.



Gambar 1. Alur Penelitian

2.1. Pengumpulan Dataset

Data citra aksara Lontara yang digunakan pada penelitian ini diperoleh dari repositori data terbuka Kaggle bertajuk “Aksara Lontara” (subfolder *lontaraV3*) yang dipublikasikan secara daring. Folder *train* pada dataset tersebut memuat total 7.452 citra yang terdistribusi merata ke dalam 23 kelas konsonan dasar aksara Lontara (a, ba, ca, da, ga, ha, ja, ka, la, ma, mpa, na, nca, nga, ngka, nra, nya, pa, ra, sa, ta, wa, ya), dengan masing-masing kelas berjumlah 324 citra. Pemanfaatan dataset publik yang telah terstandarisasi ini sejalan dengan praktik umum penelitian pengenalan aksara daerah lain di Indonesia, seperti pada aksara Lampung [1] dan aksara Sunda [13], yang juga memanfaatkan korpus citra hasil akuisisi terstruktur untuk menjamin konsistensi ukuran sampel antar kelas. Dataset yang digunakan secara spesifik adalah subset Aksara Lontara V3 yang diperoleh dari repositori Kaggle *asrulsaid/aksara-lontara*.



Gambar 2. Sampel dataset dari 23 kelas Aksara

2.2. Pembagian Dataset

Dataset dibagi melalui dua tahap pembagian secara terstratifikasi (*stratified split*) agar proporsi setiap kelas tetap seimbang pada setiap subset. Tahap pertama memisahkan 20% dari total data (1.491 citra) sebagai data pengujian (*test set*) yang dicadangkan secara eksklusif untuk evaluasi akhir dan tidak dilibatkan sama sekali dalam proses pelatihan maupun pembentukan *pseudo-label*. Sisa 80% data (5.961 citra) selanjutnya dibagi kembali menjadi 40% data berlabel (*labeled set*) sejumlah 2.384 citra yang digunakan untuk melatih model dasar, dan 60% data tidak berlabel (*unlabeled set*) sejumlah 3.577 citra yang dijadikan target prediksi *pseudo-labeling*. Proporsi 40:60 ini dipilih agar simulasi lebih merepresentasikan kondisi anotasi nyata, yaitu tersedianya anggaran anotasi yang moderat dan tidak hanya pada skenario data berlabel yang sangat ekstrem minim seperti pada sejumlah riset SSL terdahulu [10]. Rincian hasil pembagian data ditunjukkan pada Tabel 1.

Tabel 1. Rincian pembagian dataset

Subset Data	Persentase	Jumlah Citra	Fungsi
Data uji (<i>test set</i>)	20%	1.491	Evaluasi akhir model
Data berlabel (<i>labeled</i>)	40% dari sisa data	2.384	Pelatihan model dasar (<i>baseline</i>)
Data tidak berlabel (<i>unlabeled</i>)	60% dari sisa data	3.577	Target prediksi <i>Pseudo-labeling</i>

2.3. Prapemrosesan Citra

Prapemrosesan dilakukan agar data mentah seragam dan siap direpresentasikan sebagai matriks input. Setiap citra dibaca dalam format warna RGB tiga kanal, kemudian disesuaikan ukurannya (*resizing*) menjadi dimensi matriks 64×64 piksel agar seluruh sampel memiliki resolusi yang sepadan sebelum dimasukkan ke jaringan. Tahap selanjutnya adalah normalisasi intensitas piksel, yaitu membagi seluruh nilai piksel pada rentang 0–255 dengan skalar 255, sehingga rentang nilai berubah menjadi [0,1]. Transformasi ini secara empiris mampu mempercepat konvergensi fungsi objektif pada algoritma gradient *descent* dan menstabilkan skala gradien antar lapisan. Berbeda dengan praktik konversi ke citra keabuan (*grayscale*) pada penelitian aksara terdahulu [16], [17] maupun teknik pemotongan citra [14] yang umum digunakan untuk mereduksi latar belakang visual, penelitian ini tetap mempertahankan tiga kanal warna RGB karena variasi warna latar dan tinta pada citra sumber dinilai turut menyumbang informasi tekstural yang relevan bagi proses konvolusi.

2.4. Augmentasi Data & Label Encoding

Untuk memperkaya variasi visual data berlabel yang jumlahnya relatif terbatas, diterapkan augmentasi data secara *on-the-fly* menggunakan *ImageDataGenerator*. Transformasi yang digunakan meliputi rotasi acak ($\pm 10^\circ$), *zoom* (10%), pergeseran horizontal dan vertikal (masing-masing 10%), serta *shear* (10%), tanpa pembalikan horizontal karena pembalikan arah dapat mengubah makna fonemik suatu karakter aksara menjadi karakter lain yang tidak valid. Teknik augmentasi geometri ringan semacam ini telah dibuktikan mampu meningkatkan kemampuan generalisasi model CNN pada domain citra dengan jumlah sampel terbatas, seperti pada klasifikasi citra medis [15] maupun penerjemahan bahasa isyarat berbasis citra [11]. Augmentasi diterapkan secara konsisten baik pada tahap pelatihan model dasar maupun pada tahap pelatihan ulang menggunakan data gabungan. Label kelas yang berbentuk *string* (nama kelas aksara) ditransformasikan ke representasi numerik menggunakan *LabelEncoder*, kemudian dikonversi lebih lanjut menjadi format *one-hot encoding* melalui fungsi *to_categorical* sehingga setiap label direpresentasikan sebagai vektor biner berdimensi 23, sesuai jumlah kelas pada lapisan keluaran (*output layer*) model.

2.5. Arsitektur Convolutional Neural Network (CNN)

CNN adalah arsitektur jaringan saraf tiruan yang didesain khusus untuk memproses data berwujud *grid* dua dimensi seperti citra digital, dan mampu mengekstraksi atribut visual tanpa memerlukan rekayasa fitur manual [18]. Arsitektur yang diusulkan pada penelitian ini tersusun dari tiga blok konvolusi yang masing-masing memadukan lapisan konvolusi (Conv2D), normalisasi *batch* (*Batch Normalization*), dan reduksi spasial



(*Max Pooling*), dilanjutkan dengan satu lapisan tersembunyi (*Dense*) dan lapisan keluaran *Softmax*. Rincian konfigurasi lapisan secara lengkap disajikan pada Tabel 2.

Tabel 2. Konfigurasi lapisan model CNN

Lapisan (<i>Layer</i>)	Konfigurasi Parameter	Ukuran Output	Jumlah Parameter
Input	$64 \times 64 \times 3$ (RGB)	$64 \times 64 \times 3$	-
Conv2D 1	32 filter, kernel 3×3 , ReLU	$62 \times 62 \times 32$	896
<i>Batch Normalization</i> 1	-	$62 \times 62 \times 32$	128
<i>Max Pooling</i> 1	<i>pool size</i> 2×2	$31 \times 31 \times 32$	0
Conv2D 2	64 filter, kernel 3×3 , ReLU	$29 \times 29 \times 64$	18.496
<i>Batch Normalization</i> 2	-	$29 \times 29 \times 64$	256
<i>Max Pooling</i> 2	<i>pool size</i> 2×2	$14 \times 14 \times 64$	0
Conv2D 3	128 filter, kernel 3×3 , ReLU	$12 \times 12 \times 128$	73.856
<i>Batch Normalization</i> 3	-	$12 \times 12 \times 128$	512
<i>Max Pooling</i> 3	<i>pool size</i> 2×2	$6 \times 6 \times 128$	0
<i>Flatten</i>	<i>Reshape</i> vektor 1D	4.608	0
<i>Dense (Hidden)</i>	256 <i>neuron</i> , ReLU	256	1.179.904
<i>Dropout</i>	rasio 0,5	256	0
Output (<i>Dense</i>)	23 <i>neuron</i> , <i>Softmax</i>	23	5.911

Pada lapisan konvolusi, matriks citra dikalikan secara *element-wise* dengan sekumpulan filter (*kernel*) berukuran 3×3 sehingga menghasilkan *feature map* yang merepresentasikan distribusi garis, tepi, dan lengkungan dasar pembentuk karakter aksara Lontara. Fungsi aktivasi *Rectified Linear Unit* (ReLU) kemudian diterapkan pada setiap keluaran konvolusi untuk mereduksi seluruh nilai negatif menjadi nol menanamkan sifat non-linearitas yang esensial bagi jaringan untuk memetakan fungsi klasifikasi yang kompleks. Setiap keluaran konvolusi selanjutnya distabilkan melalui lapisan *Batch Normalization*, yang menormalisasi distribusi aktivasi pada setiap *mini-batch* guna mempercepat konvergensi dan mengurangi sensitivitas model terhadap inisialisasi bobot.

Selanjutnya, lapisan *Max Pooling* berukuran 2×2 disisipkan setelah setiap blok konvolusi untuk mengelola dimensionalitas *feature map* sekaligus mempertahankan fitur paling dominan, seperti titik sudut aksara yang tajam, dengan tetap memberikan sifat invarian terhadap pergeseran posisi [5]. Setelah tiga blok konvolusi dieksekusi secara bertahap (32, 64, hingga 128 filter), tensor yang dihasilkan dipipihkan melalui lapisan *Flatten* menjadi vektor berdimensi 4.608, lalu dipropagasikan ke lapisan *Dense* berkapasitas 256 *neuron*. Untuk mencegah *overfitting*, diterapkan *Dropout* dengan rasio 0,5 yang menonaktifkan separuh *neuron* secara acak pada setiap iterasi pelatihan. Pada lapisan keluaran, 23 *neuron* dikonfigurasi mewakili total kelas aksara Lontara, dipasangkan dengan fungsi aktivasi *Softmax* yang mentransformasikan logit murni menjadi distribusi probabilitas kelas. Model dikompilasi menggunakan *optimizer Adam* dengan fungsi kerugian *categorical cross-entropy* yang mengukur selisih antara distribusi probabilitas prediksi dan label sebenarnya.

2.6. Pengukuran Kinerja Model

Performa komputasi diukur menggunakan matriks konfusi (*confusion matrix*) yang membandingkan label prediksi dengan label aktual pada *test set* [12]. Dari matriks konfusi tersebut, dihitung empat metrik utama, yaitu *Accuracy* (Persamaan 1), *Precision* (Persamaan 2), *Recall* (Persamaan 3), dan *F1-score* (Persamaan 4).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

$$F1 - Score = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (4)$$



3. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil evaluasi model CNN dasar (*supervised*) yang dikomparasikan dengan hasil evaluasi model setelah penerapan *Semi-Supervised Pseudo-labeling*, berdasarkan skenario pengujian pada 1.491 citra aksara Lontara yang tidak pernah dilibatkan dalam proses pelatihan maupun pembentukan *pseudo-label*.

3.1. Arsitektur dan Ringkasan Model

Model CNN yang dibangun sesuai konfigurasi pada Tabel 2 menghasilkan total 1.279.959 parameter, terdiri atas 1.279.511 parameter yang dapat dilatih dan 448 parameter tidak dilatih (berasal dari statistik bergerak pada ketiga lapisan *Batch Normalization*). Ukuran model yang relatif ringkas ini memungkinkan proses pelatihan berjalan efisien meskipun hanya menggunakan sumber daya komputasi standar.

3.2. Evaluasi CNN Baseline (*Supervised*)

Model dasar dilatih secara eksklusif menggunakan 2.384 citra berlabel yang telah diaugmentasi, dengan maksimum 50 *epoch* dan validasi langsung terhadap *test set*. Proses pelatihan menunjukkan kurva akurasi pelatihan yang meningkat secara konsisten, diiringi penurunan nilai *loss* yang stabil hingga *callback Early Stopping* mengembalikan bobot terbaik. Evaluasi akhir model dasar pada 1.491 citra pengujian menghasilkan akurasi sebesar 99.93% dengan nilai *loss* sebesar 0.0036, sebagaimana dirangkum pada Tabel 3.

Tabel 3. Hasil evaluasi model CNN *baseline* pada data uji

Tahap	Jumlah Data Latih	Akurasi Uji	Loss Uji
CNN <i>Baseline (Supervised)</i>	2.384 citra	99.93%	0.0036

3.3. Proses *Pseudo-labeling*

Model dasar yang telah konvergen digunakan untuk menginferensi probabilitas kelas pada 3.577 citra tidak berlabel. Seleksi *pseudo-label* dilakukan berdasarkan ambang batas kepercayaan $\tau = 0.95$. Hasil seleksi menunjukkan bahwa 3.537 citra (98.88%) memiliki *confidence score* di atas ambang batas dan diterima sebagai *pseudo-label*, sedangkan sisanya sebanyak 40 citra (1.12%) dibuang karena tingkat keyakinan prediksinya berada di bawah ambang batas, sebagaimana dirangkum pada Tabel 4. Tingginya proporsi citra yang lolos seleksi mengindikasikan bahwa model dasar, meskipun hanya dilatih dari sebagian kecil data, telah memiliki keyakinan klasifikasi yang sangat tinggi pada sebagian besar pola visual aksara Lontara.

Tabel 4. Hasil seleksi *pseudo-labeling* pada ambang batas $\tau = 0,95$

Keterangan	Jumlah Citra	Persentase
Total Data Tidak Berlabel	3.577	100%
<i>Pseudo-Label</i> Diterima ($\geq \tau$)	3.537	98,88%
Data Dibuang ($< \tau$)	40	1,12%

Untuk memperkaya analisis pada tahap seleksi *pseudo-label*, dilakukan inspeksi visual terhadap citra-citra dengan *confidence score* terendah di antara 40 citra yang dibuang. Gambar 3 menyajikan dua contoh citra tersebut beserta nilai *confidence score*-nya. Citra pertama diprediksi sebagai kelas "a" dengan *confidence score* sebesar 0,788 dan *blur score* (variansi Laplacian) sebesar 2.487,8, sedangkan citra kedua diprediksi sebagai kelas "nra" dengan *confidence score* sebesar 0,877 dan *blur score* sebesar 3.615,0. Nilai *blur score* pada kedua citra tersebut tergolong tidak rendah, sehingga rendahnya *confidence score* pada kedua kasus ini kemungkinan besar bukan disebabkan oleh citra yang buram. Secara visual, citra pertama menampilkan goresan bergelombang ganda disertai bercak kecil tambahan di dekat ujung goresan, sehingga bentuknya berada pada batas kemiripan dengan pola beberapa kelas aksara lain. Citra kedua menampilkan lengkungan utama yang berimpitan dengan sebuah loop kecil tambahan, menghasilkan siluet yang menyerupai gabungan lebih dari satu



karakter. Dengan demikian, rendahnya keyakinan model pada kedua citra ini lebih besar kemungkinannya disebabkan oleh kemiripan visual antarkelas (*inter-class similarity*) pada tingkat goresan, bukan oleh keterbatasan resolusi citra maupun arsitektur CNN yang digunakan.



Gambar 3. Dua contoh citra dengan confidence score terendah di antara 40 citra yang dibuang (kiri: prediksi "a", confidence 0,788, blur score 2.487,8; kanan: prediksi "nra", confidence 0,877, blur score 3.615,0)

3.4. Penggabungan Data dan *Retraining*

Sebanyak 3.537 citra *pseudo-labeled* digabungkan dengan 2.384 citra berlabel asli, membentuk dataset pelatihan baru berjumlah 5.921 citra. Dataset gabungan ini selanjutnya digunakan untuk melatih ulang model dari kondisi bobot model dasar, dengan augmentasi, *batch size* 32, dan maksimum 50 *epoch*, menggunakan *callback* yang identik dengan tahap pelatihan sebelumnya. Kurva pelatihan ulang menunjukkan akurasi validasi yang meningkat secara stabil sejak *epoch* awal dan *loss* validasi yang menurun mendekati nol.

3.5. Evaluasi Akhir Model Semi-Supervised

Pengujian akhir pada 1.491 citra data uji yang sama dengan tahap evaluasi *baseline* menunjukkan bahwa model hasil *retraining* mencapai akurasi sebesar 100% dengan nilai *loss* sebesar 0.0000572. Laporan klasifikasi (*classification report*) menunjukkan bahwa nilai *precision*, *recall*, dan *F1-score* mencapai 1,00 secara merata pada keseluruhan 23 kelas aksara, tanpa satu pun kesalahan klasifikasi pada *test set*. Matriks konfusi yang dihasilkan menunjukkan diagonal utama yang terisi penuh tanpa nilai pada sel-sel non-diagonal.

Tabel 5. Perbandingan hasil evaluasi akhir model CNN *baseline* dan model Semi-Supervised pada data uji

Model Arsitektur	Jumlah Data Latih	Akurasi	Precision	Recall	F1-Score
CNN <i>Baseline</i>	2.384 citra	99,93%	1,00	1,00	1,00
CNN + Semi-Supervised	5.921 citra	100%	1,00	1,00	1,00

Secara kuantitatif, penerapan *pseudo-labeling* meningkatkan akurasi pengujian dari 99.93% menjadi 100%, atau setara dengan margin peningkatan sebesar 0.07 poin persentase. Selisih ini terlihat kecil secara nominal karena model *baseline* yang dilatih hanya dari 2.384 citra berlabel telah lebih dahulu mencapai performa yang sangat tinggi, sehingga ruang perbaikan (*margin for improvement*) yang tersisa relatif sempit. Tingginya akurasi model *baseline* yang hanya dilatih dengan 40% data berlabel (2.384 citra) mengindikasikan adanya efek kejenuhan (*saturation effect*) pada dataset Kaggle yang digunakan, mengingat citra pada dataset tersebut relatif bersih, terstandardisasi, dan memiliki variasi visual yang rendah antar-citra dalam satu kelas. Kondisi inilah yang menjelaskan mengapa margin peningkatan akurasi setelah penerapan *pseudo-labeling* hanya sebesar 0,07 poin persentase, karena ruang perbaikan yang tersedia bagi SSL memang sudah sangat terbatas sejak tahap *baseline*. Meskipun demikian, temuan ini tetap memiliki nilai ilmiah yang penting: alur (*pipeline*) SSL berbasis *pseudo-labeling* yang dibangun pada penelitian ini terbukti *feasible*, stabil, dan siap digunakan sebagai kerangka kerja pelatihan pada kasus dengan keterbatasan anotasi. Implikasinya, apabila *pipeline* yang sama diterapkan pada dataset manuskrip aksara Lontara tulisan tangan asli yang lebih heterogen, dengan variasi gaya tulisan, kemiringan, dan tingkat kebisingan visual yang lebih tinggi, maka kesenjangan

akurasi antara model *baseline* dan model *Semi-Supervised* berpotensi lebih signifikan, sehingga manfaat pendekatan *pseudo-labeling* dapat teramati secara lebih representatif.

4. KESIMPULAN

Berdasarkan hasil implementasi dan analisis komparasi yang telah dilakukan, arsitektur *Convolutional Neural Network* yang diperkuat dengan *Batch Normalization*, *Dropout*, dan augmentasi data, serta diintegrasikan dengan metode *Semi-Supervised Learning Pseudo-labeling*, berhasil meningkatkan kinerja pengenalan citra aksara Lontara pada 23 kelas konsonan dasar. Model dasar yang dilatih hanya dengan 2.384 citra berlabel (40% dari sisa data setelah pemisahan data uji) mencapai akurasi pengujian sebesar 99.93%. Proses *pseudo-labeling* dengan ambang batas kepercayaan $\tau = 0.95$ berhasil menambahkan 3.537 citra tambahan (98,88% dari 3.577 citra tidak berlabel) tanpa keterlibatan anotasi manual, sehingga total data pelatihan meningkat menjadi 5.921 citra dan akurasi pengujian akhir meningkat menjadi 100%, dengan *precision*, *recall*, dan *F1-score* mencapai 1,00 pada seluruh kelas. Penelitian ini mengonfirmasi kelayakan (*feasibility*) penggunaan teknik *Semi-Supervised* dalam studi pelestarian dokumen aksara daerah dengan keterbatasan anotasi manual, sekaligus menunjukkan bahwa kombinasi strategi regularisasi yang tepat dapat mendorong performa model mendekati batas optimal meski hanya menggunakan sebagian kecil data beranotasi.

Penelitian ini juga memiliki keterbatasan yang perlu dicermati. Karena dataset yang digunakan bersumber dari repositori citra yang telah terstandarisasi dengan jumlah sampel seragam pada setiap kelas (324 citra per kelas), tingkat variasi gaya penulisan tangan, kemiringan, maupun derajat kebisingan visual kemungkinan lebih rendah dibandingkan korpus tulisan tangan asli yang dikumpulkan langsung dari berbagai kontributor independen, seperti yang dilakukan pada penelitian pengenalan aksara Lota Ende [4] maupun aksara Jawa [6]. Akibatnya, akurasi *baseline* yang sangat tinggi pada penelitian ini berpotensi belum sepenuhnya merepresentasikan kondisi nyata di lapangan ketika model dihadapkan pada manuskrip aksara Lontara hasil tulisan tangan yang lebih heterogen. Penelitian lanjutan disarankan untuk mengevaluasi skema *Semi-Supervised Pseudo-labeling* yang sama pada korpus citra tulisan tangan asli dengan tingkat variasi visual yang lebih tinggi, agar manfaat SSL terhadap peningkatan akurasi dapat teramati secara lebih signifikan dan representatif.

REFERENSI

- [1] A. Mulyanto, E. Susanti, F. Rossi, W. Wajiran, dan R. I. Borman, "Penerapan *Convolutional Neural Network* (CNN) pada Pengenalan Aksara Lampung Berbasis Optical Character Recognition (OCR)," *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 7, no. 1, hlm. 52–57, 2021, doi: 10.26418/jp.v7i1.43265.
- [2] C. K. Dewa, A. L. Fadhilah, dan A. Afiahayati, "Convolutional Neural Networks for Handwritten Javanese Character Recognition," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 12, no. 1, hlm. 83–94, 2018, doi: 10.22146/ijccs.31144.
- [3] S. N. Rahmawati, E. W. Hidayat, dan H. Mubarak, "Implementasi Deep Learning pada Pengenalan Aksara Sunda Menggunakan Metode Convolutional Neural Network," *INSERT: Information System and Emerging Technology Journal*, vol. 2, no. 1, hlm. 46–58, 2021, doi: 10.23887/insert.v2i1.37405.
- [4] R. Aryanto, M. Alfian Rosid, dan S. Busono, "Penerapan Deep Learning untuk Pengenalan Tulisan Tangan Bahasa Aksara Lota Ende dengan Menggunakan Metode Convolutional Neural Networks," *Jurnal Informasi dan Teknologi*, vol. 5, no. 1, hlm. 258–264, 2023.
- [5] A. Risnawati, F. K. M. Yasin, dan T. Wahyudi, "Deteksi dan Pengenalan Tulisan Tangan Aksara Lontara Berbasis Model Deep Learning," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, vol. 11, no. 1, hlm. 45–52, 2022.
- [6] A. Hidayatullah, M. R. Ma'arif, dan S. Widaningsih, "Klasifikasi Aksara Jawa Menggunakan *Convolutional Neural Network* (CNN) Berbasis Arsitektur VGG16," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, hlm. 312–318, 2021.
- [7] Mustafa, N. Nur, F. Wajidi, A. A. Asnan Cirua, dan Ismaun, "Pengenalan Huruf Aksara Lontara Menggunakan Metode Convolutional Neural Network," *Journal of Computer and Information System (J-CIS)*, vol. 7, no. 1, hlm. 34–42, 2024.
- [8] W. Arthanugraha, Z. Zainuddin, dan A. L. Arda, "The Implementation of *Convolutional Neural Network* in Recognize Lontara Text," *Jurnal Informatika*, vol. 11, no. 2, hlm. 65–72, 2024, doi: 10.31294/inf.v11i2.20328.
- [9] D.-H. Lee, "Pseudo-Label: The Simple and Efficient *Semi-Supervised Learning* Method for Deep neural networks," dalam *ICML Workshop on Challenges in Representation Learning*, 2013.



- [10] R. Ardiansyah dan A. Wijaya, "Penerapan *Semi-Supervised Learning* dengan Pendekatan *Pseudo-labeling* pada Klasifikasi Pola Batik Indonesia," *Jurnal Ilmu Komputer dan Informasi*, vol. 16, no. 1, hlm. 23–31, 2023.
- [11] R. Z. Fadillah, A. Irawan, dan M. Susanty, "Data Augmentasi untuk Mengatasi Keterbatasan Data pada Model Penerjemah Bahasa Isyarat Indonesia (BISINDO)," *Jurnal Informatika*, vol. 8, no. 2, hlm. 208–214, 2021.
- [12] T. H. Pinem dan Z. P. Putra, "Evaluasi Kinerja Algoritma Klasifikasi Deep Learning dalam Prediksi Diabetes," *Jurnal Ilmiah FIFO*, vol. 17, no. 1, hlm. 17–28, 2025.
- [13] A. Mubarak dan N. Suciati, "Pengenalan Citra Karakter Tulisan Tangan Aksara Sunda Menggunakan Metode Deep Convolutional Neural Network," *Jurnal Ilmiah Komputasi*, vol. 19, no. 3, hlm. 315–324, 2020.
- [14] S. Saifullah dan A. Yudhana, "Analisis Perbandingan Pengolahan Citra Asli dan Hasil Cropping untuk Identifikasi Telur," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 2, no. 3, hlm. 341–350, 2016.
- [15] D. Husen, "Evaluasi Teknik Augmentasi Data untuk Klasifikasi Tumor Otak Menggunakan CNN pada Citra MRI," *TEKNIMEDIA: Teknologi Informasi dan Multimedia*, vol. 5, no. 2, hlm. 219–228, 2024.
- [16] I. G. S. M. Diyasa dan R. Romadhon, "Klasifikasi Karakter Tulisan Aksara Jawa Menggunakan Algoritma Convolutional Neural Network," *Seminar Keinsinyuran*, vol. 3, no. 1, hlm. 927–936, 2023.
- [17] R. R. Riansyah, Y. I. Nurhasanah, dan I. A. Dewi, "Sistem Pengenalan Aksara Sunda Menggunakan Metode Modified Direction Feature dan Learning Vector Quantization," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 3, no. 1, hlm. 17–30, 2017, doi: 10.28932/jutisi.v3i1.651.
- [18] A. Purnama, S. Bahri, G. Gunawan, T. Hidayatulloh, dan S. Suhada, "Implementation of Deep Learning for Handwriting Imagery of Sundanese Script Using *Convolutional Neural Network* Algorithm (CNN)," *ILKOM Jurnal Ilmiah*, vol. 14, no. 1, hlm. 10–16, 2022.