

Klasifikasi Bahasa Isyarat Menggunakan Metode *Convolutional Neural Network* dengan Arsitektur *MobileNet*

Ariefah Khairina Islahati^{1✉}, Deny Nugroho Triwibowo²⁾, Rosyid Ridlo Al Hakim³⁾

^{1,2,3)} Program Studi Sistem Informasi, Universitas Harapan Bangsa

¹⁾ ariefahrina28@gmail.com[✉], ²⁾ denynugroho@uhb.ac.id, ³⁾ rosyid@uhb.ac.id

ABSTRACT

Deaf individuals are people with hearing impairments, classified as either completely deaf or hard of hearing, which hinders verbal communication. According to the World Health Organization (WHO), over 430 million people worldwide, including 34 million children, experience hearing loss. In Indonesia, the most commonly used communication method among the deaf community is the Indonesian Sign System (SIBI). With advancements in technology, artificial intelligence methods such as Convolutional Neural Networks (CNN) have been widely used for image processing and pattern recognition to support communication for the hearing impaired. However, previous studies have shown limitations in data quantity, class coverage, and a lack of evaluation involving lightweight architectures such as MobileNet, particularly for SIBI recognition. This research aims to develop a sign language classification model using CNN with the MobileNet architecture. The dataset used consists of 5,720 SIBI hand gesture images, including manually collected samples for the letters "J" and "Z." Preprocessing involved image resizing and data augmentation to prevent overfitting. The model was trained for 30 epochs. Evaluation results indicate that MobileNet achieved an accuracy of 74.15%, significantly outperforming the baseline CNN model, which only reached 19%. These results demonstrate that MobileNet is more efficient in recognizing visual patterns in sign language and offers a practical solution for implementation on resource-constrained devices. Nevertheless, further improvements are needed to enhance classification performance across all alphabet letters.

Keywords: Sign Language Classification, CNN, MobileNet, Data Augmentation.

ABSTRAK

Tunarungu merupakan penyandang disabilitas yang mengalami gangguan pendengaran, baik tuli maupun kurang pendengaran, yang menghambat komunikasi verbal. Menurut *World Health Organization* (WHO), lebih dari 430 juta orang di dunia mengalami gangguan pendengaran, termasuk 34 juta anak-anak. Di Indonesia, komunikasi tunarungu umumnya menggunakan Sistem Bahasa Isyarat Indonesia (SIBI). Perkembangan teknologi saat ini memungkinkan pemanfaatan kecerdasan buatan, seperti *Convolutional Neural Network* (CNN), dalam pengenalan pola dan pengolahan citra untuk mendukung komunikasi penyandang tunarungu. Namun, berbagai penelitian sebelumnya menunjukkan keterbatasan pada jumlah data, cakupan kelas, serta kurangnya evaluasi pada arsitektur ringan yang efisien seperti *MobileNet* dalam konteks bahasa isyarat SIBI. Penelitian ini bertujuan untuk mengembangkan model klasifikasi bahasa isyarat menggunakan CNN dengan arsitektur *MobileNet*. Dataset terdiri dari 5.720 gambar huruf SIBI, termasuk tambahan untuk huruf "J" dan "Z". *Pre-processing* dilakukan dengan penyesuaian ukuran gambar dan teknik augmentasi untuk mencegah *overfitting*. Model dilatih selama 30 *epoch* untuk memastikan proses belajar yang cukup. Hasil evaluasi menunjukkan bahwa *MobileNet* mencapai akurasi sebesar 74,15%, jauh lebih tinggi dibanding CNN konvensional yang hanya memperoleh 19%. Temuan ini menunjukkan bahwa *MobileNet* lebih efisien dalam mengenali pola visual bahasa isyarat, sekaligus memberikan solusi praktis untuk implementasi di perangkat dengan keterbatasan sumber daya. Meskipun demikian, hasil klasifikasi menunjukkan masih adanya ruang perbaikan dalam mengklasifikasikan seluruh huruf secara konsisten dan akurat.

Kata kunci: Klasifikasi Bahasa Isyarat, CNN, *MobileNet*, Augmentasi

I. PENDAHULUAN

Tunarungu merupakan penyandang disabilitas yang mengalami gangguan pada yang diklasifikasikan ke dalam kategori tuli (*deaf*) atau kurang pendengaran (*hard of hearing*) [1]. Menurut data *World Health Organization* (WHO) lebih dari 430 juta jiwa di seluruh dunia, termasuk 34 juta anak-anak dengan gangguan pendengaran [2]. Media yang sering digunakan dalam komunikasi dengan bahasa isyarat, khususnya di Indonesia adalah Sistem Bahasa Isyarat Indonesia (SIBI) [3].

Di Era saat ini, banyak teknologi informasi yang telah dikembangkan untuk mendukung komunikasi penyandang tunarungu, salah satu teknologi yang memanfaatkan kamus SIBI untuk mengidentifikasi simbol dari gestur tangan secara efektif dengan memanfaatkan teknologi *artificial intelligence* seperti pengolahan citra dan pengenalan pola. Metode yang sering digunakan adalah *Convolutional Neural Network* (CNN) yang sangat efektif dalam mengenali dan mengklasifikasikan pola dalam data visual, termasuk citra digital yang mempermudah proses klasifikasi gerakan tangan menjadi huruf sesuai dengan kamus bahasa isyarat yang digunakan serta sebagai bentuk komunikasi yang sesuai dengan kondisi mereka [4] [5].

Berbagai penelitian sebelumnya mengenai pengenalan bahasa isyarat menunjukkan hasil yang beragam. Penelitian [6] memperoleh *F1-score* tertinggi sebesar 99,57% menggunakan CNN dengan arsitektur Xception, meskipun waktu pelatihannya lebih lama dibanding metode lain seperti KNN yang hanya mencapai *F1-score* 86,95% namun dengan waktu pelatihan tercepat. Penelitian [7] menggunakan CNN dalam aplikasi web untuk mengenali abjad SIBI dan mendapatkan akurasi 80,76%, namun data yang digunakan terbatas hanya dari empat orang.

Sementara itu, Penelitian [8] menggunakan SSD-*MobileNetV2* untuk pengenalan bahasa isyarat secara *real-time* dan mencatat akurasi 91%, meskipun performa menurun pada mode non-*real-time* menjadi 60%. Penelitian lain seperti [9] dan [10] menggunakan *MobileNet* dan menunjukkan akurasi tinggi (hingga 97%), tetapi masih berfokus pada pengenalan angka atau huruf dalam ASL, bukan SIBI. Di sisi lain, penelitian [11] membandingkan beberapa model transfer *learning* dan menemukan akurasi tertinggi dicapai oleh arsitektur tertentu seperti *Xception*, sementara ResNet50 justru memiliki performa terendah.

Secara umum, kelemahan utama dari penelitian-penelitian sebelumnya terletak pada terbatasnya jumlah data dan kelas yang digunakan, kurangnya variasi kondisi pengujian yang mencerminkan situasi nyata, serta belum adanya pendekatan yang secara eksplisit membandingkan performa antara CNN konvensional dan arsitektur ringan seperti *MobileNet* dalam konteks klasifikasi bahasa isyarat SIBI. Sebagian besar penelitian cenderung berfokus pada pencapaian akurasi


tinggi, namun mengesampingkan aspek efisiensi komputasi yang penting untuk penerapan di perangkat dengan sumber daya terbatas. Hasil penelitian ini menunjukkan bahwa meskipun CNN konvensional memiliki kompleksitas yang lebih tinggi, akurasi yang dicapai masih lebih rendah dibandingkan *MobileNet*, yang terbukti lebih ringan, efisien, dan mampu mengenali seluruh alfabet SIBI secara lebih lengkap—termasuk penambahan huruf “J” dan “Z” yang belum banyak dikaji dalam studi sebelumnya.

CNN merupakan jaringan saraf tiruan yang unggul dalam mengklasifikasikan pola visual yang kompleks, seperti gerakan tangan dalam bahasa isyarat. Kelebihanannya terletak pada kemampuan mengekstrak fitur dari gambar tanpa perlu intervensi manusia, sehingga sangat efektif dalam pengenalan citra. Hal ini membuat CNN sangat cocok untuk pengenalan bahasa isyarat, dengan akurasi tinggi [12]. Solusi yang tepat berdasarkan masalah yang tertera adalah penggunaan arsitektur *MobileNet* yang memiliki konvolusi yang diklasifikasikan sebagai *depthwise* atau *pointwise*, menjadikannya salah satu arsitektur CNN yang dapat digunakan untuk memenuhi kebutuhan komputasi yang besar [4].

MobileNet terbukti efektif dalam mengidentifikasi suatu objek dalam masalah klasifikasi pengenalan citra [13] yang memungkinkan penerapan model *deep learning* pada perangkat tanpa mengurangi akurasi secara signifikan, penerapan *MobileNet* menjadi solusi yang lebih cepat dan efisien untuk klasifikasi gerakan tangan. Hal ini bertujuan untuk meningkatkan akurasi dalam klasifikasi gerakan tangan yang sesuai dengan kamus Bahasa isyarat SIBI [14].

II. METODE

Penelitian ini menggunakan teknik analisis deskriptif untuk menilai kinerja metode dalam mengklasifikasikan gambar bahasa isyarat dengan data yang dikumpulkan dikategorikan, diurutkan, dan diukur dalam satuan tertentu [15].



Gambar 1. Alur Penelitian [16]

Pada Gambar 1 adalah ilustrasi alur penelitian langkah-langkah dalam penelitian yang menggunakan metode CNN dengan arsitektur *MobileNet* yang meliputi pertama studi literatur; kedua pengumpulan data; ketiga Pre-Processing Data; keempat Penerapan Metode CNN ; kelima Penerapan Arsitektur *MobileNet*

keenam Hasil Akurasi Metode dan yang terakhir adalah Evaluasi

A. Studi Literatur

Peneliti melakukan studi literatur terkait dengan topik yang dibahas, yaitu bahasa isyarat, klasifikasi, CNN, dan *MobileNet*. Studi literatur ini membantu menambah wawasan dalam memahami landasan teori yang mendukung penelitian serta melihat penelitian-penelitian terdahulu yang relevan. [17].

1) Tunarungu

Orang dengan gangguan pendengaran atau penyandang tuli yang memiliki keterbatasan dalam mendengar secara total atau sebagian sehingga menghadapi kesulitan memproses informasi bahasa melalui pendengaran, baik dengan maupun tanpa alat bantu dengar (*hearing aid*). Kemiskinan kosakata, kesulitan berbahasa, dan kesulitan berkomunikasi adalah semua efek dari kehilangan pendengaran yang dialami anak tunarungu. Hal ini berdampak besar pada kemampuan mereka dibandingkan dengan anak-anak tanpa hambatan pendengaran [18] [19].

2) SIBI

SIBI lebih sering digunakan di institusi pendidikan formal, tetapi komunitas tunarungu kurang menggunakannya dalam kehidupan sehari-hari. manual [20]. Pengguna bahasa isyarat memanfaatkan kombinasi gerakan tangan dan mimik wajah untuk membentuk komunikasi yang dapat dipahami oleh sesama pengguna bahasa isyarat, seperti yang ditunjukkan pada Gambar satu (1) yang menggambarkan ilustrasi SIBI [21].



Gambar 2. Bahasa Isyarat SIBI

3) Machine Learning

Machine Learning ML adalah cabang kecerdasan buatan yang berfokus pada pembuatan sistem yang dapat belajar secara mandiri tanpa perlu diprogram secara berulang *data yang* biasanya dibagi menjadi dua bagian: pembelajaran data dan pengujian data [22].

Kecerdasan buatan yang dikenal sebagai pembelajaran mesin berkonsentrasi pada penggunaan

algoritma dan teknik khusus untuk prediksi, pengenalan pola, dan klasifikasi [23].

1) Klasifikasi

klasifikasi citra digunakan untuk mengenali isyarat tangan dalam bahasa isyarat menggunakan arsitektur CNN yang dioptimalkan, seperti *MobileNet*, yang mampu memberikan prediksi akurat dengan efisiensi komputasi yang tinggi. [24].

2) Deep Learning

Deep learning dapat mempelajari representasi data yang semakin kompleks, mulai dari pola sederhana hingga pola abstrak yang lebih mendalam dan tersembunyi. Metode ini sangat cocok untuk tugas-tugas yang memerlukan pengenalan [25].

3) Convolutional Neural Network

CNN yang memiliki kemampuan untuk mengenali pola dan karakteristik secara otomatis dengan minimal pra-pemrosesan manual, jenis jaringan saraf tiruan ini paling sering digunakan untuk memproses data dalam bentuk gambar. terdiri dari berbagai lapisan yang berurutan. Lapisan convolution mengekstraksi fitur dasar seperti sudut dan tepi; lapisan pooling mengurangi dimensi fitur untuk mengurangi beban komputasi dan mencegah overfitting; dan Fully Connected Layer menggabungkan informasi untuk membuat prediksi [26].

4) MobileNet

Arsitektur seperti *MobileNet* sering digunakan dalam penelitian yang menggunakan CNN untuk klasifikasi bahasa isyarat karena mampu menangani data citra berukuran besar dengan menggunakan sumber daya komputasi yang terbatas

MobileNet varian ringan dari CNN, memungkinkan implementasi yang lebih cepat dan hemat memori tanpa mengorbankan akurasi prediksi yang dapat digunakan pada perangkat yang memiliki keterbatasan daya komputasi dan memori. Selain itu, *multiplier* lebar dan resolusi memungkinkan *MobileNet* untuk disesuaikan dengan kebutuhan aplikasi [4] [27].

MobileNet V2 juga memiliki peningkatan yang mengurangi jumlah parameter dan komputasi, untuk membantu mengevaluasi seberapa baik model dalam melakukan klasifikasi yaitu dengan mengukur kinerja hasil seperti akurasi, presisi, *recall* dan *f1-score* [28], Berikut beberapa rumus yang dapat digunakan untuk mengukur kinerja hasil seperti akurasi, *presisi*, *recall* dan *f1-score* :

- a. Akurasi mengukur seberapa akurat model menghasilkan prediksi yang benar dari semua prediksi yang dibuat, dengan rumus seperti berikut:

$$akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

- b. Presisi mengukur seberapa tepat model dalam memprediksi kelas positif berapa yang benar benar positif dari semua prediksi positif, dengan rumus seperti berikut

$$Presisi = \frac{TP}{TP + FP} \quad (2)$$

- c. Recall mengukur seberapa baik model dalam menemukan semua positif yang benar, dengan rumus seperti berikut

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

- d. *F1-Score* adalah kombinasi dari *Recall* dan Presisi yang digunakan untuk menjaga keseimbangan terutama saat data positif dan negatif sangat berbeda, dengan rumus seperti berikut

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

B. Pengumpulan Data

Pengumpulan data yang diperlukan untuk penelitian. Proses Pengumpulan data diambil dari Kaggle dataset dengan menggunakan link (<https://www.kaggle.com/datasets/alvinbintang/sibi-dataset>) yang berupa sekumpulan gambar dari Bahasa isyarat SIBI dalam bentuk dataset dengan total sebanyak 24 huruf alfabet kecuali huruf J dan Z dengan jumlah data adalah 5.280 gambar yang didapat dari Kaggle secara sekunder serta 440 gambar yang diambil secara pribadi untuk huruf “J” dan “Z” yang akan digabungkan dengan dataset dari kaggle sehingga total gambar yang digunakan adalah 5.720 gambar.


C. Pre-Processing Data

Pre-processing yang bertujuan untuk mempermudah pelatihan model CNN dengan menyesuaikan ukuran gambar, sehingga semua gambar memiliki jumlah piksel yang sama yaitu 128 pixel dan diformat ke dalam bentuk JPG. Selain itu, dataset perlu diperbanyak melalui teknik augmentasi seperti rotasi, flipping, pemotongan gambar, dan zoom untuk mencegah overfitting. dataset dibagi menjadi tiga bagian, yaitu 70% (4.056) untuk pelatihan, 20% (1.014) untuk validasi, dan 10% (650) untuk pengujian. Metode split 70:20:10 dinilai lebih ideal dibandingkan 80:20 karena menyediakan data validasi terpisah, sehingga memungkinkan pemantauan performa model selama pelatihan dan mencegah overfitting [29], Selain itu, penggunaan *Image Data Generator* memungkinkan augmentasi data secara dinamis selama proses pelatihan, yang memperkaya variasi gambar dan meningkatkan kemampuan generalisasi model [7].

D. Penerapan Metode CNN

Metode CNN dilatih menggunakan gambar bahasa isyarat yang menunjukkan huruf-huruf alfabet SIBI. Metode CNN dilatih untuk mengklasifikasikan gerakan tangan dalam gambar bahasa isyarat menjadi huruf-huruf alfabet dilakukan dengan memproses beberapa lapisan gambar bahasa isyarat untuk mengidentifikasi dan mengekstraksi pola visual yang kompleks dari data gambar. Setelah mencoba beberapa variasi jumlah *epoch*, dipilih 30 *epoch* karena jumlah ini dianggap cukup untuk memberikan kemampuan belajar yang optimal tanpa berisiko menyebabkan *overfitting* pada data latih. Penerapan Arsitektur *MobileNet*.

Hasil akurasi merupakan nilai parameter keberhasilan dari pengujian keseluruhan data yang digunakan dan menjadi indikator kinerja model dalam mengidentifikasi data uji secara tepat, serta membantu dalam evaluasi apakah metode yang diterapkan sudah optimal atau masih memerlukan penyesuaian [30].



Gambar 3. Alur Metode

Gambar 3 merupakan alur dari metode yang akan digunakan untuk mencari hasil akurasi dengan penjelasan sebagai berikut:

1) Pembagian Data:

Tahapan ini membagi dataset menjadi dua bagian, yaitu Data Latih dan Data Uji, Dengan total data 5.720 *dataset*.

2) Data Latih:

Setelah data terbagi, Data Latih diproses lebih lanjut dalam Pelatihan Metode.

3) Pelatihan Metode:

a. Penerapan metode yang akan digunakan dalam penelitian, yaitu CNN dan *MobileNet* yang memiliki dua cabang:

1. Metode CNN: Model CNN dasar yang dilatih menggunakan data latih.
2. Metode CNN + *MobileNet*: Model yang menggunakan arsitektur *MobileNet* sebagai bagian dari CNN untuk meningkatkan efisiensi dan akurasi.

b. Data Uji

Data Uji digunakan di bagian akhir untuk mengukur performa model melalui proses evaluasi setelah pelatihan selesai.

c. Evaluasi

Setelah pelatihan kedua metode selesai di evaluasi. Data Uji digunakan untuk mengukur akurasi model yang telah dilatih.

d. Pengujian

Hasil dari evaluasi digunakan dalam tahap Pengujian, dimana akurasi kedua model akan dibandingkan untuk menentukan model terbaik berdasarkan performanya dalam mengklasifikasikan data uji.

E. Evaluasi Data

Setelah proses pelatihan selesai, evaluasi data dilakukan menggunakan data uji (10%) yang tidak pernah digunakan selama pelatihan untuk mengevaluasi seberapa baik model mampu mengenali dan mengklasifikasikan gerakan tangan dalam bahasa isyarat pada data baru yang belum pernah dilihat model.

III. HASIL DAN PEMBAHASAN

A. Pre-Processing Data

Dalam penelitian ini, data gambar mengalami beberapa tahapan *pra*-pemrosesan (*preprocessing*) untuk meningkatkan akurasi dan efisiensi model CNN dengan arsitektur *MobileNet*. Data mentah memiliki variasi tinggi dalam ukuran, pencahayaan, orientasi, dan resolusi, sehingga diperlukan penyesuaian agar lebih seragam sebelum dimasukkan ke dalam model. Tahapan pertama adalah normalisasi, yaitu mengubah nilai piksel dari rentang 0–255 menjadi 0–1 melalui proses *rescaling* ($1./255$) pada setiap kanal warna (R, G, dan B). Proses ini dilakukan dengan *ImageDataGenerator* agar model dapat mengenali pola visual secara stabil tanpa terganggu oleh perbedaan intensitas warna atau pencahayaan. Format RGB tetap digunakan karena *MobileNet* bekerja dengan input tiga kanal untuk menangkap informasi warna secara optimal.

Langkah kedua adalah augmentasi data, yang bertujuan untuk meningkatkan keberagaman data latih tanpa perlu menambah data secara manual. Augmentasi dilakukan dengan transformasi seperti rotasi, pergeseran, *zooming*, dan *flipping* menggunakan *ImageDataGenerator*. Teknik ini membantu model beradaptasi terhadap variasi visual gestur tangan yang mungkin terjadi di kondisi nyata, sehingga mampu meningkatkan kemampuan generalisasi dan mengurangi risiko *overfitting*. Dengan memperluas representasi visual dari masing-masing kelas isyarat, model belajar dari berbagai kemungkinan tampilan gestur, sehingga dapat mengenali isyarat yang sama dalam kondisi pencahayaan atau sudut pandang yang berbeda.

Tahap terakhir adalah *resizing*, yaitu menyesuaikan ukuran semua gambar ke dimensi 128×128 piksel agar sesuai dengan *input* layer model CNN. Ukuran ini dipilih karena cukup kecil untuk efisiensi komputasi, tetapi masih mempertahankan informasi penting dari gestur tangan. Konsistensi ukuran *input* sangat penting untuk memastikan bahwa proses ekstraksi fitur berjalan optimal tanpa kehilangan konteks visual. Dengan kombinasi normalisasi, augmentasi, dan *resizing*, model mendapatkan data yang bersih, stabil, dan bervariasi, sehingga dapat belajar secara efektif. Tahapan ini secara signifikan berkontribusi terhadap pencapaian akurasi 74,15% pada model *MobileNet* dalam klasifikasi bahasa isyarat SIBI.

B. Hasil Pelatihan

Pengujian CNN dan *MobileNet* dalam penelitian ini bertujuan untuk mengevaluasi performa model dalam mengklasifikasikan Bahasa isyarat.


1) CNN



Gambar 4. Grafik Akurasi dan Loss CNN

Berdasarkan Gambar nomor empat (4) diatas grafik akurasi mengalami peningkatan data latih pada setiap epoch mulai dari 0.1115 hingga 0.8306, Grafik penurunan mengalami penurunan pada setiap epoch pada saat training data mulai dari 35.3516 hingga 0.5205 pada epoch ke 15. Grafik yang terlihat hanya menguji data latih dan data validasi sebanyak 15 epoch karena dari validasi loss 14 ke 15 mengalami penurunan yang drastis sehingga epoch tidak dilanjutkan karena parameter *Early Stopping* yang menunjukkan bahwa model CNN sudah cukup baik dalam mengenali data pelatihan.

2) MobileNet



Gambar 5. Grafik Akurasi dan Loss MobileNet


Berdasarkan Gambar nomor lima (5) diatas Grafik akurasi pelatihan menunjukkan bahwa akurasi model meningkat dengan cepat pada awal pelatihan. Karena model mulai mempelajari pola dasar dari data, Setelah beberapa epoch, akurasi mulai stabil, mulai dari 0. 0.2740 hingga 0.9593,

Grafik penurunan mengalami penurunan pada setiap *epoch* pada saat training data mulai dari 5.0713 hingga 0.6745 yang menunjukkan bahwa *MobileNet* sudah cukup baik dalam mengenali data pelatihan.

C. Hasil Pengujian

Evaluasi model dalam klasifikasi bahasa isyarat bertujuan untuk mengukur kinerja sistem dalam mengklasifikasikan isyarat tangan ke dalam kategori yang benar. Model yang digunakan adalah CNN dengan arsitektur *MobileNet*, yang telah dilatih menggunakan *dataset* bahasa isyarat SIBI. Evaluasi ini dilakukan untuk mengetahui seberapa baik model mengenali pola dari gambar isyarat tangan, serta untuk mengidentifikasi kemungkinan kesalahan yang terjadi dalam prediksi.

1) CNN



Gambar 6. Hasil Pengujian Confusion Matrix CNN

Dari Hasil Klasifikasi yang terlihat pada gambar enam (6), klasifikasi yang menggunakan CNN konvensional hanya menghasilkan akurasi **19%**, terlihat bahwa model mengalami kesulitan mengenali sebagian besar huruf, dengan nilai *precision* dan *recall* nol pada beberapa kelas. Hasil ini jauh lebih rendah dibandingkan penelitian oleh [7] yang mencapai **80,76%**, meskipun dengan dataset terbatas. Demikian pula, penelitian oleh [11] dengan transfer learning pada huruf hijaiyah juga menunjukkan akurasi tinggi hingga **100%** pada beberapa arsitektur.

Hasil ini menunjukkan bahwa arsitektur CNN konvensional belum mampu menggeneralisasi pola-pola visual dari dataset SIBI secara efektif. Akurasi yang sangat rendah, yakni hanya 19%, disertai dengan nilai *precision* dan *recall* sebesar nol pada beberapa kelas, mengindikasikan bahwa model mengalami kesulitan dalam mengenali ciri khas dari sebagian besar huruf isyarat.

Ketidakseimbangan dalam performa tiap kelas menandakan bahwa fitur yang diekstraksi oleh CNN konvensional belum cukup representatif terhadap variasi bentuk tangan dalam bahasa isyarat SIBI. Dengan demikian, pendekatan ini belum optimal untuk klasifikasi isyarat tangan

SIBI, dan diperlukan penggunaan arsitektur yang lebih efisien atau teknik pembelajaran lanjutan untuk meningkatkan performa model. detail hasil dari *Precision*, *recall* dan *f1-score*. Hasil Evaluasi dari model CNN dapat dilihat pada tabel 1 berikut ;

Tabel 1. Hasil Laporan Evaluasi CNN


Kategori	precision	recall	f1-score
A	0.00	0.00	0.00
B	0.00	0.00	0.00
C	0.14	0.04	0.06
D	0.67	0.24	0.35
E	0.03	0.04	0.03
F	0.09	0.12	0.10
G	0.00	0.00	0.00
H	1.00	0.40	0.57
I	0.06	0.04	0.05
J	1.00	0.80	0.89
K	0.08	0.04	0.05
L	0.67	0.16	0.26
M	0.07	0.16	0.10
N	0.23	0.12	0.16
O	0.38	0.12	0.18
P	0.46	0.48	0.47
Q	0.17	0.20	0.19
R	0.14	0.04	0.06
S	0.00	0.00	0.00
T	0.15	0.24	0.19
U	0.00	0.00	0.00
V	0.00	0.00	0.00
W	0.06	0.48	0.10
X	0.00	0.00	0.00
Y	0.60	0.12	0.20
Z	1.00	1.00	1.00
Akurasi	0.19		

Berdasarkan tabel satu (1) menunjukkan bahwa model CNN konvensional memiliki kinerja yang sangat rendah, dengan akurasi hanya sebesar 0,19 atau 19%. Artinya, dari seluruh data uji, hanya 19% prediksi yang dilakukan model sesuai dengan label yang benar. Beberapa kategori huruf seperti A, B, G, S, U, V, dan X menunjukkan *precision*, *recall*, dan *f1-score* sebesar 0,00, yang mengindikasikan bahwa model benar-benar gagal mengenali huruf-huruf tersebut. Sebaliknya, huruf J dan Z menunjukkan performa yang sangat baik, bahkan *f1-score* untuk huruf Z mencapai nilai sempurna. Kategori seperti H, P, dan Q memiliki performa sedang, sedangkan sebagian besar huruf lainnya menunjukkan nilai *f1-score* yang rendah hingga sangat rendah.

Ketimpangan performa ini mengindikasikan bahwa model belum mampu menangkap pola visual yang membedakan antar kelas dengan baik. Salah satu penyebab utama kemungkinan adalah distribusi data yang tidak merata antar huruf, sehingga model lebih terlatih dalam mengenali huruf tertentu yang memiliki lebih banyak contoh, dan gagal mengenali huruf dengan jumlah data yang lebih sedikit. Selain itu, arsitektur CNN dasar yang digunakan mungkin belum cukup kompleks untuk mengekstraksi fitur penting dari bahasa isyarat, terutama dalam kasus huruf dengan kemiripan bentuk atau gestur.

Peningkatan kinerja model memerlukan penerapan beberapa strategi seperti augmentasi data secara menyeluruh untuk memperkaya variasi citra, pemilihan arsitektur yang lebih efisien seperti *MobileNet*, serta penyesuaian *hyperparameter* agar lebih optimal. Selain itu, penggunaan teknik penanganan data tidak seimbang seperti *oversampling* pada kelas minoritas atau penerapan metode *weighted loss* dapat membantu model belajar secara lebih adil dari seluruh kelas yang ada.

2) MobileNet



Gambar 7. Hasil Pengujian Confusion Matrix *MobileNet*

Dari hasil klasifikasi yang ditampilkan pada Gambar tujuh (7), terlihat bahwa penggunaan arsitektur *MobileNet* menghasilkan akurasi sebesar 74,15% pada data uji. Meskipun akurasi ini cukup baik, masih terdapat variasi performa yang signifikan antar kelas, terutama pada huruf-huruf yang memiliki bentuk mirip atau saling tumpang tindih. Evaluasi model dilakukan menggunakan metrik *precision*, *recall*, dan *F1-score* untuk setiap kelas, dengan rincian hasil evaluasi ditampilkan pada Tabel dua (2).

Beberapa kelas seperti huruf A, J, dan Z menunjukkan performa yang sangat tinggi dengan *F1-score* di atas 0,9, menandakan model mampu mengenali pola visualnya dengan baik. Namun, huruf seperti D, K, dan P memiliki *F1-score* rendah, yang menunjukkan tantangan dalam membedakan gestur dengan bentuk serupa. Hal ini mengindikasikan perlunya perbaikan lebih lanjut, baik dalam aspek *preprocessing* maupun penyesuaian arsitektur model agar dapat menangani variasi antar kelas dengan lebih efektif.

Pencapaian ini tergolong kompetitif jika dibandingkan dengan penelitian sebelumnya. Misalnya Penelitian, [31] menggunakan *SSD-MobileNet* untuk mendeteksi huruf BISINDO dan menyatakan model berhasil melakukan klasifikasi dengan baik, meskipun tidak menyebutkan akurasi secara eksplisit. Sementara itu, Penelitian [8] yang menggunakan *SSD-MobileNetV2* untuk enam huruf SIBI berhasil mencapai akurasi 91% dalam kondisi *real-time*, namun dengan ruang lingkup yang lebih sempit.

Akurasi 74,15% pada klasifikasi seluruh huruf bahasa isyarat SIBI menunjukkan bahwa arsitektur *MobileNet* mampu memberikan performa yang jauh lebih baik dibandingkan CNN konvensional. Tidak hanya itu, model ini juga menunjukkan nilai *precision*, *recall*, dan *f1-score* yang lebih stabil di sebagian besar kelas, menandakan kemampuannya dalam mengenali variasi bentuk tangan secara lebih konsisten. Meskipun terdapat beberapa kelas dengan performa yang masih perlu ditingkatkan, secara keseluruhan *MobileNet* terbukti unggul dalam menyeimbangkan antara akurasi dan efisiensi komputasi.

Tabel 2. Hasil Laporan Evaluasi CNN dengan *MobileNet*

Kategori	precision	recall	f1-score
A	0.8621	1.0000	0.9259
B	0.9474	0.7200	0.8182
C	1.0000	0.7200	0.8372
D	1.0000	0.2000	0.3333
E	1.0000	0.4000	0.5714
F	0.9130	0.8400	0.8750
G	0.7667	0.9200	0.8364
H	0.3500	0.2800	0.3111
I	0.9545	0.8400	0.8936
J	0.9259	1.0000	0.9615
K	0.2727	0.2400	0.2553
L	0.8000	0.1600	0.2667
M	0.9565	0.8800	0.9167
N	0.7059	0.9600	0.8136
O	0.7143	1.0000	0.8333
P	0.6667	0.1600	0.2581
Q	0.6757	1.0000	0.8065
R	1.0000	0.9600	0.9796
S	0.5208	1.0000	0.6849
T	0.9091	0.8000	0.8511
U	0.6207	0.7200	0.6667
V	0.4528	0.9600	0.6154
W	0.7727	0.6800	0.7234
X	0.8929	1.0000	0.9434
Y	0.6364	0.8400	0.7241
Z	0.9615	1.0000	0.9804
accuracy	0.7415		

Berdasarkan Tabel dua (2), model CNN dengan arsitektur *MobileNet* menunjukkan performa yang cukup baik dengan akurasi keseluruhan sebesar 74,15%. Beberapa huruf seperti A, J, R, X, dan Z memiliki nilai *precision*, *recall*, dan *f1-score* yang sangat tinggi, bahkan mencapai angka sempurna (1.0000) untuk beberapa metrik.

Namun, terdapat pula huruf-huruf seperti D, K, L, dan P yang menunjukkan performa rendah, dengan *f1-score* di bawah 0,35, menandakan masih adanya kesulitan model dalam mengenali huruf-huruf tertentu, terutama yang memiliki kemiripan bentuk atau variasi visual yang tinggi. Hal ini menunjukkan bahwa meskipun secara umum model bekerja cukup baik, penyempurnaan masih diperlukan pada kelas-kelas dengan performa rendah untuk meningkatkan konsistensi klasifikasi.

Tabel 3. Tabel 1 Selisih Nilai Optimasi

CNN	CNN + <i>MobileNet</i>	Selisih
19%	74%	55%

Tabel 3 memperlihatkan bahwa model klasifikasi bahasa isyarat dengan arsitektur *MobileNet* berhasil mencapai akurasi sebesar 74,15%, jauh lebih tinggi dibandingkan model CNN konvensional dengan akurasi sebesar 19% yang diperoleh dari hasil pengujian pada data uji yang telah dipisahkan menggunakan metode *split* 70:20:10. Peningkatan signifikan ini menunjukkan bahwa *MobileNet* lebih efisien dalam mengenali pola visual kompleks pada bahasa isyarat, berkat kemampuannya mengekstraksi fitur melalui penggunaan *depthwise separable convolutions* yang secara signifikan mengurangi jumlah parameter tanpa mengorbankan akurasi.

Dengan struktur jaringan yang ringan dan komputasi yang lebih efisien, *MobileNet* tidak hanya mampu meningkatkan akurasi tetapi juga mempercepat proses pelatihan dan inferensi. Keunggulan ini menjadikannya lebih optimal untuk diterapkan dalam klasifikasi bahasa isyarat, terutama dalam skenario yang memerlukan kecepatan dan efisiensi sumber daya, seperti perangkat *mobile* atau sistem *real-time*. Sebaliknya, CNN konvensional cenderung kesulitan dalam mengenali variasi bentuk tangan yang kompleks dan menghasilkan performa yang jauh lebih rendah.

Implikasi dari temuan ini sangat signifikan, terutama dalam bidang komunikasi bagi difabel. Dengan akurasi yang lebih tinggi dan efisiensi komputasi yang ditawarkan oleh *MobileNet*, teknologi ini berpotensi untuk digunakan pada aplikasi berbasis perangkat *mobile* yang dapat mendukung komunikasi bahasa isyarat secara *real-time*.

IV. KESIMPULAN

Implementasi sistem informasi medis (SIM) di Indonesia masih menghadapi tantangan kompleks, terutama terkait infrastruktur teknologi, kualitas SDM, dan implementasi kebijakan. Studi ini memperkuat bukti empiris bahwa solusi berbasis *appropriate technology*, seperti sistem *hybrid* pada Klinik Smart Medica, dapat mengurangi ketergantungan infrastruktur hingga 35%, sekaligus menyoroti pentingnya pelatihan berjenjang untuk tenaga kesehatan. Temuan ini melengkapi literatur sebelumnya dengan mengusulkan model kematangan digital yang mengintegrasikan aspek teknis, SDM, dan regulasi, khususnya pasca-terbitnya Permenkes No. 24/2022. Untuk percepatan transformasi digital, rekomendasi konkret bagi pemangku kebijakan meliputi: (1) *pilot project* terstruktur di 10 kabupaten 3T dengan alokasi anggaran Rp 2–3 miliar per kabupaten dan pendampingan selama 6 bulan; (2) pengembangan modul pelatihan SIM terstandarisasi

berbasis kurikulum Kabupaten Badung; serta (3) sosialisasi kebijakan melalui workshop berbasis kasus seperti model e-SIKLA di Lamongan. Keterbatasan studi ini terletak pada cakupan artikel terindeks (2019–2024), sehingga penelitian lanjutan disarankan menggunakan pendekatan *mixed-methods* (gabungan survei dan wawancara) serta analisis komparatif dengan negara ASEAN untuk memperdalam temuan.

REFERENSI

- [1] WHO, "Global Strategy on Digital Health 2020-2025. Geneva: WHO," Geneva, 2021.
- [2] Z. A. Tyas and W. N. Negara, "Literatur Review: Implementasi Sistem Informasi Kesehatan Puskesmas di Berbagai Daerah," *Journal of Technopreneurship and Information System (JTIS)*, vol. 5, no. 1, pp. 21–24, 2022, [Online]. Available: <http://jurnal.umb.ac.id/index.php/JTIS>
- [3] A. P. Sari, E. Dwimawati, and S. Pujiati, "Gambaran Pelaksanaan Sistem Informasi Manajemen Rumah Sakit (SIMRS) Di Instalasi Administrasi Pasien Rumah Sakit DR. H Marzuki Mahdi Bogor Provinsi Jawa Barat," *PROMOTOR Jurnal Mahasiswa Kesehatan Masyarakat*, vol. 3, no. 2, pp. 116–135, 2020, [Online]. Available: <http://ejournal.uika-bogor.ac.id/index.php/PROMOTOR>
- [4] R. A. Siregar, "Penerapan Permenkes Nomor 24 Tahun 2022 Tentang Rekam Medis Terhadap Efektivitas Pelayanan Kesehatan," *Jurnal Ilmu Hukum Kyadiren*, vol. 5, no. 2, pp. 1–12, Jan. 2024, doi: 10.46924/jihk.v5i2.182.
- [5] Kementerian Kesehatan RI, "Peraturan Menteri Kesehatan Nomor 24 Tahun 2022 tentang Rekam Medis Elektronik," Jakarta, 2022.
- [6] R. Amalia and N. Huda, "Implementasi Sistem Informasi Pelayanan Kesehatan Pada Klinik Smart Medica," *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 9, no. 3, pp. 332–338, Sep. 2020, doi: 10.32736/sisfokom.v9i3.884.
- [7] S. Rusli, "Implementasi Sistem Informasi Manajemen Rumah Sakit Dalam Pengolahan Data Rumah Sakit," *Jurnal Kesehatan Masyarakat*, vol. 10, no. 2, pp. 158–168, Dec. 2022.
- [8] I. W. W. Karsana and G. S. Mahendra, "Sistem Informasi Geografis Pemetaan Lokasi Puskesmas Menggunakan Google Maps API Di Kabupaten Badung," *Jurnal Komputer dan Informatika*, vol. 9, no. 2, pp. 160–167, Oct. 2021, doi: 10.35508/jicon.v9i2.5214.
- [9] S. Hade, A. Djalla, and A. D. P. Rusman, "Analysis the Application of Hospital Management Information Systems in an Effort to Improve Health Services in Andi Makkasau Parepare," *Jurnal Ilmiah Manusia dan Kesehatan*, vol. 2, no. 2, pp. 294–305, 2019, [Online]. Available: <http://jurnal.umpar.ac.id/index.php/makes>
- [10] S. Setiatin and S. R. Agustin, "Perancangan Sistem Informasi Pelayanan Rekam Medis Di Puskesmas Arcamanik Kota Bandung," *Jurnal Manajemen Informasi Kesehatan Indonesia*, vol. 7, no. 1, pp. 23–33, Mar. 2019, doi: 10.33560/jmiki.v7i1.207.
- [11] M. P. Sodani and E. H. Fanida, "Inovasi Pelayanan Elektronik Sistem Kesehatan Lamongan (E-SIKLA) Dalam Meningkatkan Layanan Kesehatan Di Puskesmas Kedungpring Kabupaten Lamongan," Surabaya, 2020. [Online]. Available: www.kemkes.go.id
- [12] A. Y. S. Utomo, B. Widjanarko, and Z. Shaluhiah, "Mutu Pelayanan dengan Kepuasan Pasien Rawat Inap di Rumah Sakit: Literature Review," *Media Publikasi Promosi Kesehatan Indonesia (MPPKI)*, vol. 6, no. 9, pp. 1708–1714, Sep. 2023, doi: 10.56338/mppki.v6i9.3720.
- [13] N. S. Rubiyanti and G. Suharto, "Penerapan Rekam Medis Elektronik di Rumah Sakit di Indonesia: Kajian Yuridis," *MAGISTRA Law Review*, vol. 4, no. 2, pp. 119–126, Jul. 2023, [Online]. Available: <http://jurnal.untagsmg.ac.id/index.php/malrev>

- [14] D. I. E. Eritiana, D. Pasha, and A. S. Puspaningrum, "E-Posyandu Pengolahan Data Status Tumbuh Kembang Pada Balita (Studi Kasus: Posyandu Cahaya Kartini)," *Jurnal Teknologi dan Sistem Informasi (JTSI)*, vol. 3, no. 1, pp. 27–33, Mar. 2022, [Online]. Available: <http://jim.teknokrat.ac.id/index.php/JTSI>
- [15] D. Tarmizi and M. R. Ridha, "Sistem Informasi Geografis [1] N. Haliza, E. Kuntarto, and A. Kusmana, "Pemerolehan bahasa anak berkebutuhan khusus (tunarungu) dalam memahami bahasa," *J. Genre (Bahasa, Sastra, dan Pembelajarannya)*, vol. 2, no. 1, pp. 5–11, 2020, doi: 10.26555/jg.v2i1.2051.
- [2] WHO, "Deafness and hearing loss." [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/deafness-and-hearing-loss>
- [3] R. Fatmawati, R. Asmara, Y. R. Prayogi, and R. Y. Hakkun, "Aplikasi Pembelajaran Sistem Isyarat Bahasa Indonesia (SIBI) Berbasis Voice Menggunakan OpenSIBI," *Technomedia J.*, vol. 7, no. 1, pp. 22–39, 2022, doi: 10.33050/tmj.v7i1.1690.
- [4] M. J. Sulistio and C. Lubis, "Implementasi CNN dan MobileNet untuk Mendeteksi Penyakit Pneumonia dan COVID-19 dengan Menggunakan Aplikasi Smartphone," *Nusant. J. Multidiscip. Sci.*, vol. 1, no. 4, pp. 736–745, 2023, [Online]. Available: <https://jurnal.intekom.id/index.php/njms>
- [5] E. A. Rustamaji and N. E. Harsiwi, "Analisis Pola Komunikasi Pada Anak Berkebutuhan Khusus (Tunarungu) Di SIBI Ayodya Tulada," *Sumikolah J. Ilmu Pendidik.*, vol. 2, no. 1, pp. 1–8, 2024.
- [6] M. F. Naufal and S. F. Kusuma, "Comparison Analysis of Machine Learning and Deep Learning Algorithms for Image Classification of Indonesian Language Signing Systems (Sibi)," *Jtiik*, vol. 10, no. 4, pp. 873–882, 2023, doi: 10.25126/jtiik.2023106828.
- [7] M. Sholawati, K. Auliasari, and F. Ariwibisono, "Pengembangan Aplikasi Pengenalan Bahasa Isyarat Abjad Sibi Menggunakan Metode Convolutional Neural Network (Cnn)," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 6, no. 1, pp. 134–144, 2022, doi: 10.36040/jati.v6i1.4507.
- [8] M. A. Imaddudin, I. W. W. Hamzah, and Astuti Sri, "Simulasi Penerjemah SIBI (Sistem Isyarat Bahasa Indonesia) Menggunakan Tensorflow Dan Convolutional Neural Network (CNN)," *e-Proceeding Eng.*, vol. 8, no. 6, pp. 3911–3918, 2022.
- [9] I. P. Iduar, I. K. Gede, D. Putra, and I. P. Arya, "Classification of Sign Language Numbers Using the CNN Method," *JITTER-J. Ilm. Teknol. dan Komput.*, vol. 2, no. 3, 2021.
- [10] T. N. Abu-Jamie, P. Samy, and S. Abu-Naser, "Classification of Sign-Language Using MobileNet-Deep Learning," *Int. J. Acad. Inf. Syst. Res.*, vol. 6, no. 7, pp. 29–40, 2022, [Online]. Available: www.ijeais.org/ijeaisr
- [11] Y. Brianorman and R. Munir, "Perbandingan Pre-Trained CNN: Klasifikasi Pengenalan Bahasa Isyarat Huruf Hijaiyah," *J. Sist. Info. Bisnis*, vol. 13, no. 1, pp. 52–59, 2023, doi: 10.21456/vol13iss1pp52-59.
- [12] D. H. A. Sari, S. Sa'idah, and N. K. C. Pratiwi, "Klasifikasi Jenis Kulit Wajah Menggunakan Modifikasi Convolutional Neural Network (CNN)," *e-Proceeding Eng.*, vol. 8, no. 6, pp. 3188–3194, 2022.
- [13] O. Nurul Abada, C. Rozikin, and R. Ibnu Adam, "Komparasi Penggunaan Data Lab Dan Field Condition Untuk Membangun Model Klasifikasi Penyakit Pada Daun Apel," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 4, pp. 2910–2915, 2024, doi: 10.36040/jati.v7i4.7325.
- [14] D. Samto, "Kamus SIBI Kerjasama antara Kementerian Pendidikan dan Kebudayaan dengan Lembaga Penelitian dan Pengembangan Sistem Isyarat Bahasa Indonesia." [Online]. Available: <https://pmpk.kemdikbud.go.id/sibi/>
- [15] M. Y. Balaka, "Metode penelitian Kuantitatif," *Metodol. Penelit. Pendidik. Kualitatif*, vol. 1, p. 130, 2022.
- [16] M. B. Subkhi, M. Y. Trinurais, R. K. A. Wibowo, and B. R. Prakosa, "Deteksi Bahasa Isyarat Berdasarkan SIBI (Sistem Bahasa Isyarat) menggunakan Transfer Learning," *Semin. Nas. Teknol. Sains*, vol. 3, no. 1, pp. 361–369, 2024, doi: 10.29407/stains.v3i1.4347.
- [17] Diki Hananta Firdaus, Bahtiar Imran, Lalu Darmawan Bakti, and Emi Suryadi, "KLASIFIKASI PENYAKIT KATARAK BERDASARKAN CITRA MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) BERBASIS WEB," *J. Kecerdasan Buatan dan Teknol. Inf.*, vol. 1, no. 3, pp. 18–26, Dec. 2022, doi: 10.69916/jkbt.v1i3.6.
- [18] Juherna Erna et al., "Implementasi Pendidikan Karakter pada Disabilitas Anak Tunarungu," *J. Golden Age*, vol. 4, no. 01, pp. 12–19, 2020, doi: 10.29408/jga.v4i01.1809.
- [19] M. Rafiqah, T. Meidina, and Mustafa, "Implementasi Ultrasi Dalam Operasi Penjumlahan Pada Murid Tunarungu di SLB Negeri Jenepono," pp. 2–10, 2021.
- [20] A. S. Nugraheni, A. P. Husain, and H. Unayah, "Optimalisasi Penggunaan Bahasa Isyarat Dengan Sibi Dan Bisindo Pada Mahasiswa Difabel Tunarungu Di Prodi Pgi Uin Sunan Kalijaga," *J. Holistika*, vol. 5, no. 1, p. 28, 2023, doi: 10.24853/holistika.5.1.28-33.
- [21] C. T. K. R. Mocodompis, "IMPLEMENTASI BAHASA ISYARAT DALAM AKTIVITAS PELAYANAN BARISTA KAFE SUNYI GRAND GALAXY CITY," *Pros. Konf. Nas. Sos. dan Polit.*, vol. 1, p. 228, Jan. 2023, doi: 10.32897/konaspol.2023.1.0.2373.
- [22] M. R. S. Alfarizi, M. Z. Al-farish, M. Taufiqurrahman, G. Ardiansah, and M. Elgar, "Penggunaan Python Sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning," *Karya Ilm. Mhs. Bertauhid (KARIMAH TAUHID)*, vol. 2, no. 1, pp. 1–6, 2023.
- [23] N. R. Muntari and K. H. Hanif, "Klasifikasi Penyakit Kanker Payudara Menggunakan Perbandingan Algoritma Machine Learning," *J. Ilmu Komput. dan Teknol.*, vol. 3, no. 1, pp. 1–6, 2022, doi: 10.35960/ikomti.v3i1.766.
- [24] Y. N. Paramitha, A. Nuryaman, A. Faisol, E. Setiawan, and D. E. Nurvazly, "Klasifikasi Penyakit Stroke Menggunakan Metode Naïve Bayes," *J. Siger Mat.*, vol. 04, no. 01, pp. 11–16, 2023, [Online]. Available: <https://www.kaggle.com/datasets/zzettrkalpakbal/full-filled>
- [25] S. Prasetyo and T. Dewayanto, "Penerapan Machine Learning, Deep Learning, Dan Data Mining Dalam Deteksi Kecurangan Laporan Keuangan-a Systematic Literature Review," *Diponegoro J. Account.*, vol. 13, no. 3, pp. 1–12, 2024, [Online]. Available: <http://ejournal-s1.undip.ac.id/index.php/accounting>
- [26] S. Dewi, F. Ramadhani, and S. Djasmayena, "Klasifikasi Jenis Jerawat Berdasarkan Gambar Menggunakan Algoritma CNN (Convolutional Neural Network)," *Hello World J. Ilmu Komput.*, vol. 3, no. 2, pp. 68–73, 2024, doi: 10.56211/helloworld.v3i2.518.
- [27] M. A. A. Fawwaz, K. N. Ramadhani, and F. Sthevani, "Klasifikasi Ras pada hewan peliharaan menggunakan Algoritma Convolutional Neural Network (CNN)," vol. 8, no. 1, pp. 715–730, 2020.
- [28] D. Indra, H. Herman, and F. S. Budi, "Implementasi Sistem Penghitung Kendaraan Otomatis Berbasis Computer Vision," *Komputika J. Sist. Komput.*, vol. 12, no. 1, pp. 53–62, 2023, doi: 10.34010/komputika.v12i1.9082.
- [29] Z. Xing, Y. Ma, X. Yang, and F. Nie, "Graph regularized nonnegative matrix factorization with label discrimination for data clustering," *Neurocomputing*, vol. 440, pp. 297–309, Jun. 2021, doi: 10.1016/j.neucom.2021.01.064.
- [30] A. D. Ismail, D. Erwanto, and I. Yanuartanti, "Klasifikasi Kematangan Daun Tembakau Virginia Menggunakan Pengolah Citra Digital," *J. Elektro Kontrol*, vol. 3, no. 1, pp. 1–10, 2023, doi: 10.24176/elkon.v3i1.10131.
- [31] G. Abdillah and R. Ilyas, "Deteksi Objek Bahasa Isyarat Huruf Bisindo Menggunakan SSD-MobileNet," *Kesatria J. Penerapan Sist. Inf. (Komputer dan Manajemen)*, vol. 5, no. 1, pp. 47–60, 2024.