

Pengembangan Model Pengenalan Huruf SIBI Pada Kondisi *Low-Light* Berbasis *Convolutional Neural Network*

Francisco^{*}, Syaeful Anas Aklani

Universitas Internasional Batam, Jl. Gajah Mada, Baloi-Sei Ladi, Batam 29442, Indonesia

Informasi Naskah:

Diterima: 27 Desember 2025/ Direview: 02 Januari 2026/ Direvisi: 27 Januari 2026/ Disetujui Terbit: 02 Februari 2026

DOI: 10.33369/pseudocode.13.1.14-20

*Korespondensi: framer529@gmail.com

Abstract

Deaf and speech-impaired individuals in Indonesia face communication barriers due to limited public understanding of sign language. In real use, SIBI communication often occurs in dim lighting, yet recognition models are mainly evaluated under normal illumination, motivating robust low-light recognition. This study develops a CNN model based on MobileNetV2 to recognize SIBI (Indonesian Sign Language System) letter gestures under low-light conditions (50-100 lux). The dataset comprises 5,579 images of 26 SIBI letters, divided stratified 80:10:10. The methodology includes preprocessing with Bilateral Filter, CLAHE in LAB color space, and Adaptive Gamma Correction, plus transfer learning and fine-tuning with data augmentation. Evaluation results show 97.13% test accuracy, with most errors among similar letters. Real-time testing is stable within 50-100 lux, though accuracy decreases below 50 lux or with shadows. These findings indicate that the proposed preprocessing methods and MobileNetV2 CNN maintain reliable SIBI recognition in low-light environments.

Keywords: SIBI; CNN; MobileNetV2; low-light; image preprocessing.

1. Pendahuluan

Indonesia memiliki populasi penyandang disabilitas sekitar 3,84 juta jiwa atau 1,43% dari total penduduk menurut Sensus Penduduk 2020 *Long Form* yang dirilis Badan Pusat Statistik (BPS) pada Desember 2024[1]. Bahasa Isyarat Indonesia (BISINDO) dan Sistem Isyarat Bahasa Indonesia (SIBI) merupakan dua metode komunikasi utama komunitas tunarungu di Indonesia, namun pemahaman masyarakat umum terhadap bahasa isyarat masih rendah sehingga menimbulkan hambatan komunikasi yang signifikan antara penyandang disabilitas pendengaran dan masyarakat luas.

Upaya peningkatan kesadaran dan dukungan terhadap komunikasi penyandang disabilitas telah dilakukan melalui berbagai inisiatif [2] menekankan pentingnya kampanye penggunaan bahasa isyarat agar masyarakat lebih peka terhadap kebutuhan komunikasi tunarungu, sementara [3] mengembangkan aplikasi kamus SIBI untuk anak-anak berkebutuhan khusus yang menunjukkan peran teknologi dan pendidikan dalam mendorong inklusi sosial.

Berbagai penelitian sebelumnya telah membuktikan bahwa *Convolutional Neural Network* (CNN) efektif untuk tugas pengenalan gestur tangan [4] mengembangkan aplikasi penerjemah bahasa isyarat berbasis CNN di platform Android dan memperoleh akurasi tinggi pada kondisi pencahayaan normal [5] menerapkan CNN untuk sistem pembelajaran SIBI berbasis Android dan menunjukkan bahwa model mampu mengenali berbagai bentuk tangan dengan baik. Penelitian lain oleh [6] menunjukkan bahwa *deep learning* pada perangkat *mobile* untuk penerjemahan bahasa isyarat

Indonesia secara *real-time* sehingga memperkuat potensi teknologi ini sebagai solusi komunikasi praktis di kehidupan sehari-hari[7] [8].

Pendekatan lain menggunakan kombinasi fitur skeleton dan *hand shape* untuk meningkatkan akurasi pengenalan gestur SIBI [9], sementara [10] mengembangkan sistem pengenalan abjad SIBI menggunakan algoritma YOLOv5, dan [11] menerapkan CNN *Sequential* untuk pengenalan SIBI secara *real-time* dengan tingkat akurasi yang kompetitif.

Meskipun demikian, sebagian besar penelitian tersebut menguji sistem dalam kondisi pencahayaan yang relatif ideal. Dalam kenyataan, komunikasi menggunakan bahasa isyarat berlangsung di lingkungan dengan variasi pencahayaan yang luas, termasuk kondisi *low-light* seperti di malam hari, ruangan redup, atau area dengan sumber cahaya terbatas. Pencahayaan yang buruk menurunkan kualitas citra kamera sehingga mengurangi ketepatan deteksi gestur. Namun, evaluasi pengenalan huruf SIBI pada kondisi *low-light* masih terbatas dan belum banyak dilakukan secara terukur, khususnya pada variasi intensitas cahaya (lux).

Oleh karena itu, penelitian ini mengembangkan dan mengevaluasi model CNN berbasis MobileNetV2 pada pencahayaan rendah (50-100 lux) serta menguji kombinasi *preprocessing Bilateral Filter*, CLAHE, dan *Adaptive Gamma Correction* melalui pengujian *offline* dan *real-time*. Penelitian terkini di bidang *low-light image enhancement* menunjukkan bahwa metode berbasis *deep learning* mampu meningkatkan kualitas citra pada kondisi pencahayaan minim [12][13], namun penerapannya secara spesifik untuk pengenalan bahasa isyarat, khususnya SIBI, masih sangat terbatas. Tinjauan

literatur mengungkap beberapa kekurangan penting dalam penelitian pengenalan gestur SIBI berbasis *deep learning*.

Pertama, model yang dikembangkan umumnya hanya diuji pada kondisi cahaya normal sehingga ketahanan performa pada skenario *low-light* yang sering terjadi dalam komunikasi sehari-hari belum terpetakan secara jelas.

Kedua, meskipun teknik *low-light enhancement* berkembang pesat, sangat sedikit penelitian yang mengintegrasikan pendekatan tersebut secara terstruktur ke dalam pipeline pengenalan gestur bahasa isyarat Indonesia; banyak studi hanya mencatat penurunan akurasi pada pencahayaan rendah tanpa analisis teknis yang sistematis.

Ketiga, belum ditemukan penelitian yang secara eksplisit menguji efektivitas kombinasi teknik *preprocessing* terstruktur untuk pengenalan gestur SIBI pada kondisi *low-light*, termasuk penentuan rentang pencahayaan minimal yang masih memungkinkan sistem bekerja dengan andal.

Penelitian ini dirancang untuk menjawab kekurangan tersebut dengan mengembangkan dan mengevaluasi model CNN berbasis arsitektur MobileNetV2 yang mampu mengenali gestur huruf SIBI pada kondisi *low-light* (50–100 lux) melalui kombinasi teknik *preprocessing* *Bilateral Filter*, *CLAHE*, dan *Adaptive Gamma Correction*. Pendekatan yang digunakan tidak hanya menilai penurunan akurasi pada kondisi *low-light*, tetapi juga menguji efektivitas kombinasi tiga teknik *preprocessing*, yaitu *Bilateral Filter*, *Contrast Limited Adaptive Histogram Equalization* (CLAHE), dan *Adaptive Gamma Correction*, yang dirancang untuk meningkatkan kualitas citra sebelum diproses oleh model.

Selain itu, penelitian ini menyusun protokol pengujian yang terukur, mencakup pengukuran intensitas cahaya dalam satuan lux serta evaluasi kuantitatif performa model pada skenario pengujian *offline* dan *real-time*.

Hasil yang diperoleh dapat menjadi dasar bagi pengembangan sistem penerjemah bahasa isyarat Indonesia yang lebih tangguh terhadap variasi pencahayaan dan siap diimplementasikan dalam berbagai konteks penggunaan nyata, sehingga mendukung terciptanya komunikasi yang lebih inklusif bagi komunitas tunarungu di Indonesia.

2. Metodologi Penelitian

Penelitian ini merupakan penelitian terapan dengan pendekatan eksperimen yang bertujuan mengembangkan model pengenalan huruf Sistem Isyarat Bahasa Indonesia (SIBI) pada kondisi *low-light* berbasis *Convolutional Neural Network* (CNN) menggunakan arsitektur MobileNetV2 dengan *transfer learning*.

Penelitian dilaksanakan dengan mengumpulkan data citra gestur 26 huruf SIBI (A–Z), melakukan *preprocessing* citra menggunakan kombinasi *Bilateral Filter*, *Contrast Limited Adaptive Histogram Equalization* (CLAHE), dan *Adaptive Gamma Correction*, membagi dataset secara stratified ke dalam data latih, validasi, dan uji dengan rasio 80:10:10, melatih model dalam dua tahap (*baseline training* dan *fine-tuning*), serta mengevaluasi performa model menggunakan metrik akurasi, *precision*, *recall*, *f1-score*, dan *confusion matrix*.

Pelatihan model dilakukan melalui dua tahap: *baseline training* dan *fine-tuning*. *Baseline training* adalah tahap

pelatihan awal dengan bobot *pretrained ImageNet* untuk menetapkan performa dasar, di mana seluruh layer MobileNetV2 dibekukan (*frozen*) kecuali layer klasifikasi terakhir yang disesuaikan dengan jumlah kelas gestur SIBI (26 kelas). *Fine-tuning* kemudian dilakukan dengan membuka (*unfreeze*) beberapa layer terakhir agar bobot dapat diperbarui selama pelatihan untuk mengadaptasi representasi fitur yang lebih sesuai dengan karakteristik dataset gestur SIBI pada kondisi *low-light*.

Selain evaluasi *offline*, model juga diuji secara *real-time* pada rentang intensitas cahaya 50–100 lux untuk menilai kemampuan pengenalan gestur pada kondisi pencahayaan rendah. Hasil penelitian berupa model pengenalan huruf SIBI dan prototipe sistem pengujian *real-time* pada kondisi *low-light*.

2.1. Jenis data dan teknik pengumpulan data

Data yang digunakan terdiri atas dua jenis. Data primer berupa kumpulan gambar digital gestur huruf SIBI yang diambil menggunakan kamera dengan berbagai kondisi pencahayaan termasuk kondisi *low-light*, serta hasil pengukuran performa model seperti nilai akurasi dan metrik evaluasi lainnya pada pengujian *offline* maupun *real-time*.

Data sekunder diperoleh dari literatur dan penelitian terdahulu yang berkaitan dengan pengenalan bahasa isyarat, pengolahan gambar, serta penerapan metode CNN untuk klasifikasi gestur tangan. Dataset dikumpulkan pada tiga kategori kondisi pencahayaan yang didefinisikan berdasarkan tingkat *illuminance* dalam satuan lux.


Kategori pertama adalah *low-light* dengan rentang 50–100 lux yang menjadi fokus utama penelitian ini, mengacu pada kondisi pencahayaan rendah seperti ruangan redup atau senja.

Kategori kedua adalah pencahayaan sedang dengan rentang 101–300 lux yang merepresentasikan kondisi pencahayaan dalam ruangan dengan lampu standar.

Kategori ketiga adalah pencahayaan terang dengan intensitas lebih dari 300 lux yang umumnya dijumpai pada kondisi siang hari di dalam ruangan dengan cahaya alami atau lampu yang cukup terang. Pengukuran tingkat pencahayaan dilakukan menggunakan aplikasi Lux Meter Pro2 yang dijalankan pada iPhone 11 Pro Max.

Aplikasi ini memanfaatkan sensor *ambient light* yang terdapat pada perangkat untuk memberikan estimasi nilai *illuminance*. Meskipun pembacaan lux berbasis *smartphone* tidak setara dengan lux meter terkalibrasi secara metrologis, penggunaan perangkat dan aplikasi yang sama secara konsisten pada seluruh proses pengumpulan data memastikan komparabilitas relatif antar kategori pencahayaan. Nilai lux dicatat pada saat pengambilan citra dan digunakan sebagai dasar pengelompokan data ke dalam tiga kategori kondisi pencahayaan tersebut.

Komposisi dataset berdasarkan kondisi pencahayaan disajikan pada Tabel 1. Dataset terdiri dari 2.172 citra *low-light*, 1.627 citra pencahayaan sedang, dan 1.780 citra



pencahayaan terang dengan total keseluruhan 5.579 citra. Distribusi jumlah citra per kondisi pencahayaan mencerminkan variasi natural kondisi pengambilan data yang bertujuan memastikan model dilatih dengan eksposur yang memadai terhadap kondisi *low-light* sekaligus tetap memiliki referensi dari kondisi pencahayaan yang lebih baik. Teknik pengumpulan data dilakukan melalui dokumentasi gambar dengan memotret gestur huruf SIBI menggunakan kamera pada berbagai kondisi pencahayaan termasuk kondisi normal dan *low-light*.

Gambar yang diperoleh disimpan dan diorganisasikan ke dalam folder sesuai kelas huruf untuk dijadikan dataset pelatihan dan pengujian. Selain itu, data performa model dikumpulkan melalui serangkaian eksperimen yaitu pengujian akurasi pada dataset uji dan pengujian *real-time* menggunakan prototipe sistem. Pada pengujian *real-time*, dilakukan pencatatan tingkat keberhasilan model dalam mengenali huruf SIBI pada kondisi pencahayaan rendah.

Tabel 1. Distribusi dataset berdasarkan kondisi pencahayaan

Kondisi Pencahayaan	Rentang lux(lux)	Jumlah Gambar
<i>Low-light</i>	50-100	2172
Sedang	101-300	1627
Terang	>300	1780
Total		5.579

Contoh visual citra pada masing-masing kategori pencahayaan ditunjukkan pada Gambar. 1 yang menyajikan perbandingan kualitas citra gestur huruf SIBI pada kondisi terang, sedang, dan *low-light* dari kiri ke kanan. Perbedaan tingkat pencahayaan terlihat dari tingkat kecerahan dan detail visual tangan, di mana citra terang menampilkan detail jari yang jelas, citra sedang memiliki kecerahan moderat, sedangkan citra *low-light* menunjukkan berkurangnya intensitas cahaya dan detail yang lebih samar yang menjadi dasar penerapan teknik *preprocessing* untuk meningkatkan kualitas citra pada kondisi pencahayaan rendah.




Gbr. 1. Contoh citra gestur pada berbagai kondisi pencahayaan.

2.2. Dataset dan *preprocessing*

Dataset penelitian terdiri dari 5.579 citra gestur huruf SIBI yang mencakup 26 kelas huruf alfabet (A–Z). Setiap kelas terdiri dari sekitar 220 gambar, kecuali huruf J yang berjumlah 149 gambar dan Z yang berjumlah 150 gambar karena keterbatasan pengumpulan data. Dataset dikumpulkan secara mandiri menggunakan kamera dalam berbagai kondisi pencahayaan termasuk kondisi *low-light* yang menjadi fokus utama penelitian.

Gbr. 2. Alphabet SIBI.

Untuk meningkatkan kualitas gambar pada kondisi pencahayaan minim, diterapkan rangkaian teknik *preprocessing* yang terdiri dari tiga tahapan utama. Tahap pertama menggunakan *Bilateral Filter* untuk mengurangi noise dalam gambar sambil menjaga batas objek (tangan) sehingga kontur jari tetap terlihat jelas meskipun ada gangguan visual akibat pencahayaan kurang. Tahap kedua menerapkan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) pada ruang warna LAB untuk memperkuat kontras lokal antara tangan dan latar belakang melalui pengaturan *channel luminance* (L) sehingga detail pada tangan terlihat jelas. Tahap ketiga menggunakan *Adaptive Gamma Correction* untuk mengatur tingkat kecerahan gambar secara otomatis sesuai nilai rata-rata intensitas sehingga gambar yang terlalu gelap dapat disesuaikan menjadi lebih terang dan memberikan informasi lebih jelas bagi model. Penggabungan ketiga metode ini dirancang untuk mengurangi dampak negatif dari kondisi cahaya rendah terhadap kualitas data yang diterima model CNN.



Gbr. 3. Perbandingan sebelum–sesudah *preprocessing*.

2.3. Pembagian data

Dataset yang telah mengalami tahap *preprocessing* dibagi menjadi tiga bagian untuk tujuan pelatihan, validasi, dan pengujian model. Pembagian dilakukan secara *stratified* untuk menjaga perbandingan setiap kelas di semua bagian dengan rasio 80:10:10. Pembagian ini menghasilkan 4.463 citra data training (80%), 557 citra data validasi (10%), dan 557 citra data testing (10%). Pembagian dengan rasio 80:10:10 dipilih berdasarkan praktik standar dalam *machine learning* untuk dataset berukuran sedang (5.000–10.000 sampel). Rasio ini memberikan data pelatihan yang cukup besar untuk model mempelajari variasi gestur sambil menyediakan data validasi yang memadai untuk memantau *overfitting* selama pelatihan serta data pengujian yang independen untuk evaluasi akhir.

Tabel 2. Pembagian Dataset

Jenis Data	Persentase	Jumlah Citra
Data Training	80%	4463
Data Validation	10%	557
Data Testing	10%	557
Total	100%	5.579

2.4. Arsitektur dan pelatihan model


Model yang digunakan dalam penelitian ini adalah *Convolutional Neural Network* (CNN) dengan arsitektur

MobileNetV2 sebagai dasar yang telah dilatih menggunakan dataset ImageNet (*transfer learning*).

Arsitektur ini dipilih karena bobotnya yang ringan tetapi tetap efisien untuk tugas klasifikasi gambar pada perangkat dengan sumber daya yang terbatas. Model terdiri dari lapisan konvolusi untuk mengambil fitur dari gambar gestur tangan, layer *Global Average Pooling* untuk mengurangi dimensi data, layer Dropout (0,3) untuk mengurangi *overfitting*, serta layer *fully connected* di bagian akhir untuk klasifikasi ke 26 kelas huruf SIBI menggunakan fungsi aktivasi *softmax*. Proses pelatihan dilakukan dalam dua tahap.

Tahap pertama (*baseline training*) menggunakan optimizer Adam dengan *learning rate* 0,001, fungsi kerugian *Sparse Categorical Crossentropy*, ukuran *batch* 32, dan dilakukan selama 40 *epoch* dengan input gambar berukuran 224×224 piksel. Pada fase ini, lapisan *backbone* MobileNetV2 dikunci agar bobot yang dihasilkan selama pelatihan ImageNet tetap terjaga.

Selama proses pelatihan, teknik augmentasi data diterapkan secara otomatis termasuk random *flip* horizontal, rotasi ±8%, zoom ±10%, kontras ±20%, dan kecerahan ±20% untuk meningkatkan variasi data serta mengurangi kemungkinan *overfitting*. Tahap kedua (*fine-tuning*) dilaksanakan dengan membuka 40 layer teratas dari *backbone* MobileNetV2 agar bisa dilatih kembali dengan *learning rate* yang lebih rendah (5×10^{-5}) selama 10 *epoch* tambahan. Selama proses pelatihan, diterapkan tiga *callback* yaitu *ModelCheckpoint*, *EarlyStopping* dengan ketahanan 7 *epoch*, dan *ReduceLROnPlateau* yang menurunkan *learning rate* hingga setengah jika *loss* validasi tidak mengalami penurunan setelah 3 *epoch*.



Gbr. 4. Arsitektur Model CNN Berbasis MobileNetV2 Pretrained untuk Pengenalan Gestur SIBI

Base model MobileNetV2 menggunakan bobot *pretrained* dari ImageNet dengan *inverted residual blocks* dan *depthwise separable convolutions*.

Tahap *Baseline Training*: Seluruh layer MobileNetV2 dibekukan (*frozen*), hanya layer klasifikasi terakhir yang dilatih untuk menetapkan performa dasar.

Tahap *Fine-tuning*: Layer terakhir MobileNetV2 dibuka (*unfrozen*) dan layer Dense(26 units) + *Softmax* ditambahkan

untuk mengenali 26 huruf SIBI (A-Z).

2.5. Metode analisis data

Analisis data dilakukan melalui dua pendekatan. Analisis kuantitatif menggunakan metrik akurasi dan *confusion matrix* untuk mengevaluasi performa model secara keseluruhan pada dataset gabungan yang mencakup kondisi pencahayaan *low-light* (50-100 lux), sedang (101-300 lux), dan terang (>300 lux). Akurasi dihitung dengan rumus: jumlah prediksi benar dibagi total data uji $\times 100\%$. Analisis kualitatif dilakukan melalui pengujian *real-time* pada kondisi *low-light* (50-100 lux) untuk menilai stabilitas sistem dalam skenario penggunaan nyata.

Rumus akurasi multi-kelas yang digunakan dalam penelitian ini dinyatakan pada (1).

$$Accuracy = \frac{\sum_{i=1}^C TP_i}{N} * 100\% \quad (1)$$

di mana C adalah jumlah kelas (26 huruf SIBI), TP_i adalah jumlah prediksi benar untuk kelas ke-i, dan N adalah total data testing (557 citra). Secara lebih sederhana, akurasi dapat dituliskan sebagai (2).

$$Accuracy = \frac{Total\ Prediksi\ Benar}{N} \times 100\% \quad (2)$$


Analisis kualitatif deskriptif digunakan untuk menjelaskan hasil eksperimen terutama pengujian *real-time* di kondisi *low-light*, mencatat jenis gestur yang sering salah dikenali, pengaruh tingkat pencahayaan terhadap akurasi, serta keterbatasan prototipe sistem sebagai bahan evaluasi dan rekomendasi pengembangan lebih lanjut.

3. Hasil dan Pembahasan

Penelitian ini menghasilkan model CNN berbasis MobileNetV2 yang mampu mengenali gestur huruf SIBI pada kondisi pencahayaan *low-light* dengan akurasi tinggi. Evaluasi dilakukan melalui pengujian *offline* menggunakan data uji terpisah dan pengujian *real-time* pada berbagai tingkat pencahayaan untuk melihat performa sistem dalam situasi penggunaan nyata. Selain itu, dianalisis pula pengaruh rangkaian *preprocessing* terhadap kualitas citra dan ketahanan model terhadap variasi kondisi pencahayaan, serta dibandingkan dengan hasil penelitian terdahulu yang berfokus pada pengenalan gestur bahasa isyarat.

3.1. Evaluasi *offline* model

Setelah proses pelatihan selesai, model dievaluasi



menggunakan data testing yang belum pernah dihadapi model sebelumnya. Evaluasi dilakukan dengan menghitung akurasi melalui confusion matrix. Hasil evaluasi menunjukkan bahwa dari 557 citra pada data testing, model berhasil memprediksi dengan benar sebanyak 541 citra. Dengan demikian, akurasi model pada data testing adalah 97,13%. Nilai akurasi ini menunjukkan bahwa model mampu mengenali gestur huruf SIBI dengan tingkat ketepatan yang tinggi meskipun dataset mencakup kondisi pencahayaan rendah.

Gbr. 5. Confusion matrix model pada data testing.

Confusion matrix yang dipresentasikan dalam format heatmap menunjukkan bahwa sebagian besar hasil prediksi terletak di sepanjang diagonal utama dengan nilai yang tinggi, yang menandakan bahwa model berhasil dalam mengidentifikasi sebagian besar gambar dengan akurat. Masih terdapat beberapa kesalahan pada beberapa pasangan huruf tertentu, terutama gestur yang memiliki kemiripan visual. Pola kesalahan yang paling sering terjadi melibatkan huruf U yang salah diprediksi sebagai F (2 kali) dan V (1 kali), sedangkan kesalahan lain tersebar pada pasangan huruf seperti B–F dan M–N. Penyebaran kesalahan ini mengindikasikan bahwa meskipun performa model secara umum baik, masih terdapat tantangan pada kelas gestur yang mirip terutama dalam kondisi pencahayaan rendah.

3.2. Pengujian *real-time* pada kondisi *low-light*

Selain evaluasi secara *offline*, pengujian juga dilakukan secara *real-time* untuk menilai kemampuan sistem dalam konteks penggunaan langsung. Uji coba dijalankan dengan mengoperasikan prototipe sistem di komputer atau laptop yang terhubung ke kamera, kemudian pengguna melakukan gestur huruf SIBI di depan kamera dan sistem menampilkan prediksi huruf beserta informasi tingkat pencahayaan (lux) secara langsung. Pengujian dilakukan pada berbagai kondisi pencahayaan mulai dari normal hingga pencahayaan rendah sekitar 50–100 lux yang menjadi fokus penelitian.

Pengukuran nilai lux pada pengujian *real-time* dilakukan menggunakan aplikasi Lux Meter Pro2 yang dijalankan pada iPhone 11 Pro Max, sama dengan alat yang digunakan pada tahap pengumpulan dataset. Pada saat pengujian, iPhone

ditempatkan di posisi yang berdekatan dengan area gestur tangan, dan nilai lux dicatat bersamaan dengan proses pengenalan gestur oleh sistem untuk memastikan bahwa kondisi pencahayaan terdokumentasi secara konsisten. Nilai lux ditampilkan secara *real-time* pada antarmuka prototipe sistem sebagaimana terlihat pada Gbr. 5 sehingga memungkinkan monitoring kondisi pencahayaan selama pengujian berlangsung.

Hasil pengujian menunjukkan bahwa sebagian besar huruf dapat dikenali dengan baik dalam rentang 50–100 lux. Namun beberapa huruf tertentu menunjukkan penurunan stabilitas prediksi ketika pencahayaan mendekati batas bawah atau ketika terdapat bayangan yang kuat pada area tangan. Ketika pencahayaan turun di bawah 50 lux, akurasi mulai menurun karena detail jari menjadi kurang jelas pada citra yang diterima model. Faktor lain yang memengaruhi akurasi dalam pengujian *real-time* meliputi variasi pose tangan pengguna, sudut pengambilan gambar, dan posisi kamera terhadap sumber cahaya, yang semuanya dapat menyebabkan perubahan tampilan gestur dibandingkan dengan data pelatihan.

Pengamatan selama pengujian *real-time* menunjukkan bahwa model mampu mempertahankan akurasi pengenalan yang stabil pada rentang 50–100 lux dengan sebagian besar gestur dikenali dengan benar. Pada kondisi pencahayaan di bawah 50 lux, akurasi mengalami penurunan yang cukup signifikan karena detail visual tangan menjadi sangat samar dan noise meningkat, meskipun *preprocessing* tetap diterapkan. Sebaliknya, pada kondisi pencahayaan di atas 100 lux, akurasi pengenalan cenderung meningkat karena kontras dan detail gestur lebih jelas. Hasil ini mengindikasikan bahwa rentang 50–100 lux merupakan batas operasional yang efektif untuk sistem pengenalan gestur SIBI dengan kombinasi



preprocessing yang digunakan dalam penelitian ini.

Gbr. 6. Antarmuka prototipe pengujian *real-time* huruf SIBI pada kondisi *low-light*

3.3. Pengaruh *preprocessing* terhadap performa model

Hasil pengujian menunjukkan bahwa rangkaian *preprocessing* yang digunakan memiliki peranan penting dalam mempertahankan kualitas citra pada kondisi pencahayaan rendah. *Bilateral Filter* berhasil mengurangi noise tanpa menghilangkan detail tepi tangan sehingga kontur jari tetap tajam. Penerapan CLAHE pada channel L dalam ruang warna LAB meningkatkan kontras lokal antara tangan dan latar belakang, sehingga objek tangan lebih mudah dibedakan meskipun pencahayaan redup. *Adaptive Gamma*

Correction kemudian menyesuaikan kecerahan gambar sehingga distribusi intensitas pada citra *low-light* menjadi lebih seimbang dan mendekati kualitas gambar pada pencahayaan normal.

Kombinasi ketiga teknik ini tercermin pada tingginya akurasi model yang mencapai 97,13% serta konsistensi kinerja di sebagian besar kelas gestur. Pola kesalahan yang tersisa umumnya disebabkan oleh bayangan yang menutupi sebagian jari atau variasi posisi tangan yang cukup berbeda dari data pelatihan, sehingga fitur visual yang diterima kamera menjadi kurang informatif meskipun telah melalui proses *preprocessing*. Pengujian *real-time* pada berbagai tingkat pencahayaan memberikan gambaran mengenai batas kemampuan sistem, yaitu bahwa *preprocessing* mampu mengurangi dampak *low-light* hingga titik tertentu, tetapi tetap dibutuhkan tingkat pencahayaan minimum dan kontrol lingkungan agar performa pengenalan tetap stabil.

3.4. Perbandingan dengan penelitian terdahulu

Penelitian-penelitian sebelumnya yang mengembangkan sistem pengenalan gestur SIBI umumnya dilakukan pada kondisi pencahayaan normal dan melaporkan akurasi tinggi di atas 95% dalam lingkungan yang terkontrol [4] mengembangkan aplikasi penerjemah bahasa isyarat berbasis CNN di platform Android dan mencapai akurasi tertinggi sebesar 97% pada pencahayaan normal, sedangkan [5] menerapkan CNN untuk pembelajaran SIBI berbasis Android dan menunjukkan bahwa CNN efektif dalam mengenali pola dan bentuk tangan [6] mengembangkan aplikasi penerjemah bahasa isyarat Indonesia menjadi suara berbasis Android menggunakan TensorFlow, dan [14] menggunakan CNN untuk pengenalan BISINDO pada berbagai kondisi pencahayaan, namun belum membahas huruf SIBI pada kondisi *low-light* [3] [15] [16].

Dibandingkan penelitian-penelitian tersebut, penelitian ini memberikan kontribusi tambahan dengan berfokus pada skenario pencahayaan rendah yang lebih menantang dan menyediakan protokol pengujian yang terstruktur untuk berbagai tingkat intensitas cahaya. Meskipun beroperasi dalam kondisi *low-light*, tingkat akurasi yang dicapai (97,13%) tetap sebanding dengan penelitian terdahulu pada pencahayaan normal, yang menunjukkan bahwa kombinasi *preprocessing* dan arsitektur MobileNetV2 mampu mempertahankan kinerja sistem. Temuan ini melengkapi literatur dengan menunjukkan bahwa ketahanan model terhadap variasi pencahayaan dapat ditingkatkan melalui desain *preprocessing* yang tepat dan dapat menjadi dasar bagi pengembangan aplikasi *mobile* pengenalan bahasa isyarat yang lebih robust di masa depan

4. Kesimpulan

Penelitian ini menunjukkan bahwa model CNN berbasis arsitektur MobileNetV2 mampu mengenali gestur huruf SIBI dengan akurasi tinggi yaitu 97,13% pada data uji yang mencakup kondisi pencahayaan *low-light* setelah melalui tahap *preprocessing* *Bilateral Filter*, *CLAHE*, dan *Adaptive Gamma Correction*. Sistem dikembangkan dengan pembagian data secara stratified, penerapan augmentasi, serta pengujian

baik secara *offline* maupun *real-time* sehingga memberikan gambaran menyeluruh mengenai performa model dalam skenario penggunaan nyata.

Pengujian *real-time* menunjukkan bahwa sistem mampu mengenali gestur huruf SIBI secara stabil pada rentang pencahayaan sekitar 50–100 lux, sementara akurasi mulai menurun ketika intensitas cahaya berada di bawah batas tersebut atau ketika bayangan kuat menutupi area tangan. Faktor-faktor yang memengaruhi akurasi di antaranya intensitas pencahayaan, kemiripan bentuk beberapa gestur (seperti U–F–V dan B–F), keberadaan bayangan pada jari, serta variasi sudut pengambilan gambar dan pose tangan pengguna.

Penelitian ini masih memiliki keterbatasan dalam hal stabilitas sistem pada kondisi lingkungan yang sangat bervariasi dan pada gestur dengan kemiripan visual tinggi. Selain itu, evaluasi kuantitatif akurasi model secara terpisah pada berbagai rentang pencahayaan (*low-light*, sedang, terang) belum dilakukan; pengujian dilakukan pada dataset gabungan dengan fokus pengujian *real-time* pada rentang 50–100 lux.

Pengembangan lebih lanjut disarankan untuk melakukan evaluasi kuantitatif akurasi model pada berbagai rentang pencahayaan secara terpisah, menambah variasi data pelatihan dari berbagai sudut kamera dan kondisi pencahayaan ekstrem, mengeksplorasi teknik *preprocessing* berbasis *deep learning*, serta memperluas pengenalan dari level huruf ke kata atau kalimat agar mendukung komunikasi yang lebih kompleks.

Referensi

- [1] Badan Pusat Statistik, *Potret penyandang disabilitas di Indonesia Hasil Long Form SP2020*. Jakarta: Badan Pusat Statistik, 2024. [Online]. Available: <https://www.bps.go.id/en/publication/20241220dc0f8be5ab92199f8b9/potret-penyandang-disabilitas-di-indonesia--hasil-long-form-sp2020.html>
- [2] R. Mandasari and S. Winduwati, "Upaya Public Relations Pusbisindo dalam Mengampanyekan Penggunaan Bahasa Isyarat Indonesia di Kalangan Masyarakat," *Prologia*, vol. 6, no. 2, pp. 355–361, Nov. 2022, doi: 10.24912/pr.v6i2.15572.
- [3] S. Syamsuddin, T. Pristiwaluyo, W. A. Saleh, and Z. Zulfithrah, "Development of Indonesian Sign Language System (SIBI) Dictionary Application for Students with Special Needs," *AL-ISHLAH J. Pendidik.*, vol. 15, no. 3, pp. 3132–3143, Sep. 2023, doi: 10.35445/alishlah.v15i3.3529.
- [4] R. H. Alfikri, M. S. Utomo, H. Februriyanti, and E. Nurwahyudi, "PEMBANGUNAN APLIKASI PENERJEMAH BAHASA ISYARAT DENGAN METODE CNN BERBASIS ANDROID," *J. Teknoinfo*, vol. 16, no. 2, p. 183, Jul. 2022, doi: 10.33365/jti.v16i2.1752.
- [5] A. R. Syulistyo, D. S. Hormansyah, and P. Y. Saputra, "SIBI (Sistem Isyarat Bahasa Indonesia) translation using Convolutional Neural Network (CNN)," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 732, no. 1, p. 012082, Jan. 2020, doi: 10.1088/1757-899X/732/1/012082.
- [6] Nasha Hikmatia A.E. and M. I. Zul, "Aplikasi Penerjemah Bahasa Isyarat Indonesia menjadi Suara berbasis Android menggunakan Tensorflow," *J. Komput. Terap.*, vol. 7, no. 1, pp. 74–83, Jun. 2021, doi: 10.35143/jkt.v7i1.4629.
- [7] Y. Xu, D. Li, C. Li, Z. Yuan, and Z. Dai, "LiSA-MobileNetV2: an

- extremely lightweight deep learning model with Swish activation and attention mechanism for accurate rice disease classification,” *Front. Plant Sci.*, vol. 16, Aug. 2025, doi: 10.3389/fpls.2025.1619365.
- [8] A. Rakhmadi, A. Yudhana, and S. Sunardi, “CNN-Based SIBI Sign Language Recognition Alphabet: Exploring the Impact of Hardware on Model Training,” *J. Appl. Eng. Technol. Sci.*, vol. 7, no. 1, pp. 224–246, Dec. 2025, doi: 10.37385/jaets.v7i1.7071.
- [9] E. Rakun and N. F. Setyono, “Improving Recognition of SIBI Gesture by Combining Skeleton and Hand Shape Features,” *J. Ilmu Komput. dan Inf.*, vol. 15, no. 2, pp. 69–79, Jul. 2022, doi: 10.21609/jiki.v15i2.1014.
- [10] D. Permana and J. Sutopo, “APLIKASI PENGENALAN ABJAD SISTEM ISYARAT BAHASA INDONESIA (SIBI) DENGAN ALGORITMA YOLOv5,” *J. Simantec*, vol. 11, no. 2, pp. 231–240, Jul. 2023, doi: 10.21107/simantec.v11i2.19783.
- [11] O. D. Nurhayati, D. Eridani, and M. H. Tsalavin, “Sistem Isyarat Bahasa Indonesia (SIBI) Metode Convolutional Neural Network Sequential secara Real Time,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 4, pp. 819–828, Aug. 2022, doi: 10.25126/jtiik.2022944787.
- [12] J. Liang, Y. Xu, Y. Quan, B. Shi, and H. Ji, “Self-Supervised Low-Light Image Enhancement Using Discrepant Untrained Network Priors,” *IEEE Trans. Circuits Syst. Video Technol.*, vol. 32, no. 11, pp. 7332–7345, Nov. 2022, doi: 10.1109/TCSVT.2022.3181781.
- [13] M. H. Farook, Dewi Astria; Yusuf, “Image Processing and Object Detection in the Indonesian Sign System (SIBI) for Hearing-Impaired Communication,” *J. Appl. Informatics Comput.*, vol. 10, no. 1, pp. 729–736, 2026, doi: <https://doi.org/10.30871/jaic.v10i1.11395>.
- [14] S. Dwijayanti, H. -, S. I. Taqiyyah, H. Hikmarika, and B. Y. Suprpto, “Indonesia Sign Language Recognition using Convolutional Neural Network,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 12, no. 10, 2021, doi: 10.14569/IJACSA.2021.0121046.
- [15] S. A. Putri, Murinto, and Sunardi, “Alphabet SIBI sign language recognition using YOLOv11 for real-time gesture detection,” *J. Mandiri IT*, vol. 11, no. 1, pp. 123–135, 2025, doi: <https://doi.org/10.35335/mandiri.v14i1.408>.
- [16] F. Farhana, Abdul Rezha Efrat Najaf, and Reisa Permatasari, “BISINDO Sign Language Interpreter System Using YOLOv8 and CNN,” *bit-Tech*, vol. 8, no. 1, pp. 598–607, 2025, doi: 10.32877/bt.v8i1.2638.