

IDENTIFIKASI ISYARAT TANGAN BISINDO DENGAN ALGORITMA CNN DAN *TRANSFER LEARNING* MENGGUNAKAN MOBILENETV2

Raihan Fahlevi, Chaerur Rozikin

Informatika, Universitas Singaperbangsa Karawang
Jl. HS.Ronggo Waluyo, Puseurjaya, Telukjambe Timur, Karawang, Indonesia
raihanf2701@gmail.com

ABSTRAK

Bahasa Isyarat Indonesia (BISINDO) merupakan bentuk komunikasi visual yang digunakan oleh komunitas tuli dan tunarungu di Indonesia. Minimnya pemahaman masyarakat umum terhadap BISINDO sering kali menjadi hambatan dalam proses komunikasi, sehingga dibutuhkan teknologi yang mampu menerjemahkan isyarat tangan secara otomatis. Penelitian ini bertujuan untuk mengembangkan sistem pengenalan huruf BISINDO berbasis citra digital menggunakan algoritma *Convolutional Neural Network* dan pendekatan *transfer learning* dengan arsitektur MobileNetV2. Dataset yang digunakan terdiri dari gambar huruf A–Z BISINDO yang diperoleh melalui proses augmentasi citra. Data kemudian diproses menjadi ukuran 224x224 piksel agar sesuai dengan input model. Model dilatih menggunakan fungsi aktivasi ReLU, fungsi *loss Categorical Crossentropy*, dan optimizer Adam. Hasil pelatihan menunjukkan bahwa model mampu mengenali huruf BISINDO dengan akurasi validasi sebesar 95% dan akurasi pengujian sebesar 93,33%. Hasil ini membuktikan bahwa penggunaan *transfer learning* dengan MobileNetV2 efektif dalam membangun sistem pengenalan huruf BISINDO secara cepat dan akurat. Sistem ini diharapkan dapat menjadi solusi awal dalam menjembatani komunikasi antara pengguna BISINDO dan masyarakat umum secara lebih efisien.

Kata kunci : Klasifikasi Bahasa Isyarat, Deep Learning, CNN

1. PENDAHULUAN

Komunikasi merupakan aspek fundamental dalam interaksi manusia, memfasilitasi pertukaran ide, informasi, dan emosi. Bagi individu dengan gangguan pendengaran atau bicara, bahasa isyarat seperti Bahasa Isyarat Indonesia (BISINDO) menjadi alat komunikasi utama [1]. Namun, kendala bahasa antara pengguna bahasa isyarat dan masyarakat umum menciptakan kesenjangan komunikasi yang signifikan. Bisindo digunakan sebagai bahasa isyarat dalam komunikasi sehari-hari oleh komunitas tunarungu dengan menggunakan gerakan tangan dan ekspresi wajah. Seperti halnya bahasa daerah, Bisindo memiliki variasi penggunaan di setiap daerah [2].

Saat ini, machine learning dan deep learning sangat populer dan memiliki banyak keunggulan untuk dikembangkan. Metode yang digunakan adalah *Convolutional Neural Network* (CNN). CNN digunakan untuk mendeteksi dan mengenali objek. Salah satu kelebihanannya adalah bahwa, karena tidak membutuhkan banyak komputasi, CNN dianggap sebagai model terbaik untuk menyelesaikan masalah deteksi dan pengenalan objek. Dengan menggunakan metode *cross-validation* sepuluh kali, CNN dalam penelitian sebelumnya mencapai akurasi sebesar 92,33% [3].

Pengenalan bahasa isyarat berbasis teknologi komputer telah mengalami perkembangan signifikan dengan kemajuan dalam pembelajaran mesin dan pengolahan citra. *Convolutional Neural Network* (CNN) telah terbukti efektif dalam berbagai tugas pengenalan pola dan klasifikasi gambar, termasuk pengenalan tulisan tangan dan deteksi wajah. Teknologi ini juga relevan untuk pengenalan bahasa

isyarat, di mana CNN mampu mengekstrak fitur visual kompleks dari gerakan tangan [4].

Transfer learning telah menjadi strategi yang menonjol dalam pengembangan model pengenalan gambar. Model *pre-trained* seperti MobileNetV2 menawarkan efisiensi dalam hal komputasi dan dapat digunakan sebagai basis untuk mengembangkan model pengenalan bahasa isyarat dengan adaptasi minimal. MobileNetV2, dengan arsitektur yang ringan namun kuat, dirancang untuk digunakan dalam perangkat mobile, memungkinkan implementasi model yang lebih portabel dan efisien.

Meskipun ada banyak penelitian tentang pengenalan bahasa isyarat menggunakan CNN, sebagian besar fokus pada Bahasa Isyarat Amerika (ASL), *British Sign Language* (BSL) dan SISTEM ISYARAT BAHASA INDONESIA (SIBI) [5]. Penelitian yang secara khusus menangani Bahasa Isyarat Indonesia (BISINDO) masih terbatas. Selain SIBI, BISINDO diresmikan pada Kongres Nasional keenam Gerkatin di Bali pada tahun 2002 dengan tujuan mempertahankan bahasa isyarat alami di Indonesia [6].

Penelitian ini bertujuan untuk mengatasi kesenjangan tersebut dengan mengembangkan model pengenalan huruf BISINDO menggunakan CNN dengan pendekatan *transfer learning* menggunakan MobileNet V2. Melalui pengembangan sistem ini, penelitian diharapkan dapat memberikan kontribusi signifikan dalam mendukung komunikasi yang lebih inklusif dan mengurangi kesenjangan komunikasi antara penyandang tunarungu dan masyarakat umum di Indonesia.

2. TINJAUAN PUSTAKA

2.1. Penelitian terdahulu

Pada yang dilakukan Suharjito, dkk pada tahun 2021 penelitian dilakukan untuk mengatasi masalah dengan dataset yang terbatas dengan menggunakan model *Convolutional Neural Network* (CNN) dan *transfer learning* dari *ImageNet* dan *Kinectic*. Sensor Sony Exmor RS IMX240 16 megapiksel ponsel Samsung Galaxy S6 digunakan untuk mengumpulkan data. Dataset ini terdiri dari 200 video yang memiliki dua penanda tangan dan sepuluh kata. Akurasi validasi tertinggi adalah 100% dan akurasi pengujian tertinggi adalah 97,5%. Kedua hasil ini dicapai dengan menggunakan model *transfer learning Inception* [7].

Penelitian yang dilakukan oleh Sholawati, dkk pada tahun 2022 menunjukkan bahwa aplikasi pengenalan huruf SIBI berbasis *Convolutional Neural Network* mampu mengenali gestur abjad dengan tingkat akurasi yang cukup baik. Model CNN dilatih menggunakan 416 citra dengan parameter pelatihan 50 epoch dan batch size 32, menghasilkan akurasi pelatihan sebesar 90,05%. Hasil ini menunjukkan kesesuaian yang baik antara akurasi pelatihan dan validasi, yang tampak dari grafik akurasi yang naik secara stabil dengan perbedaan yang kecil. Evaluasi menggunakan *confusion matrix* menghasilkan akurasi klasifikasi sebesar 80,76%, dengan kendala utama pada huruf-huruf yang memiliki bentuk gestur serupa seperti B, F, M, N, dan S, serta kegagalan dalam mengenali huruf J dan Z yang melibatkan gerakan dinamis [8].

Penelitian yang dilakukan oleh Ida Bagus Adisimakrisna Peling, dkk pada tahun 2024 dengan mengembangkan sistem penerjemah bahasa isyarat berbasis Computer Vision menggunakan TensorFlow Lite dan dataset *American Sign Language* (ASL). Sistem ini dirancang untuk mendeteksi gerakan tangan berupa huruf dan kata dalam alfabet ASL melalui kamera laptop atau komputer. Tujuan dari pengembangan ini adalah untuk mempermudah masyarakat dalam mempelajari bahasa isyarat, terutama mereka yang tidak memiliki latar belakang disabilitas. Berdasarkan hasil pengujian, sistem mampu mencapai akurasi sebesar 81% pada pengujian pertama dengan 11 data uji, dan 73% pada pengujian kedua dengan 26 data uji [9].

2.2. BISINDO

BISINDO merupakan metode komunikasi yang sangat efisien dan dapat digunakan tidak hanya oleh penyandang tuli, tetapi juga oleh seluruh lapisan masyarakat. Dalam upaya mengurangi kesenjangan komunikasi dan menciptakan lingkungan yang lebih inklusif, Gerkatin menyelenggarakan kelas pembelajaran bahasa isyarat BISINDO yang terbuka untuk umum [10].


2.3. Deep Learning

Deep learning merupakan salah satu subdisiplin dari *machine learning* yang berperan dalam membangun representasi data secara otomatis melalui jaringan saraf tiruan yang terdiri dari banyak lapisan. Teknik ini menggunakan struktur jaringan berlapis yang memungkinkan transformasi data dari bentuk awal menjadi bentuk yang lebih abstrak dan bermakna secara bertahap. Tidak seperti pendekatan konvensional yang mengandalkan fitur buatan manusia, *deep learning* dapat secara mandiri mengidentifikasi dan mempelajari pola atau fitur penting langsung dari data mentah dengan bantuan algoritma pelatihan canggih. Pendekatan ini menjadikan *deep learning* sangat efektif dalam menangani tugas-tugas kompleks yang membutuhkan pemrosesan data dalam skala besar [11].

Teknologi *deep learning* mengalami lonjakan perkembangan yang sangat signifikan dan telah digunakan secara luas di berbagai sektor. Kemampuannya terbukti mampu menyempurnakan kinerja sistem dalam menyelesaikan berbagai permasalahan kompleks yang dulunya sulit ditangani, seperti identifikasi wajah, interpretasi bahasa manusia, pengenalan objek visual, hingga pengendalian sistem navigasi pada kendaraan tanpa pengemudi. [12].

2.4. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu pendekatan dalam *machine learning* yang dikembangkan dari model *Multi-Layer Perceptron* (MLP) dan dioptimalkan untuk menangani data visual dua dimensi seperti gambar. Ide dasar dari CNN diilhami oleh proses biologis otak manusia dalam mengidentifikasi dan mengolah informasi visual, yang telah mulai diteliti sejak dekade 1980-an. CNN tersusun atas beberapa komponen utama yang saling terhubung dan bekerja secara bertahap. Salah satunya adalah *convolution layer*, yang berfungsi mengekstrak fitur-fitur visual penting dari input citra dengan menggunakan filter atau kernel tertentu. Output dari proses ini kemudian diproses oleh *activation function*, seperti ReLU, yang menambahkan elemen non-linear ke dalam jaringan. Selanjutnya, *pooling layer* diterapkan untuk menyederhanakan representasi fitur dengan cara mengurangi jumlah dimensi, sehingga mempercepat proses komputasi dan membantu mencegah *overfitting* [13].




Gambar 1. Arsitektur CNN

2.5. TensorFlow

TensorFlow merupakan sebuah platform open-source yang dikembangkan oleh Google untuk mendukung pembuatan dan pelatihan model dalam bidang machine learning dan *deep learning*. Platform ini pertama kali diperkenalkan pada tahun 2015 oleh tim *Google Brain* dan sejak saat itu menjadi salah satu framework yang paling banyak digunakan dalam pengembangan kecerdasan buatan. TensorFlow dirancang untuk mempermudah para peneliti dan pengembang dalam menciptakan berbagai model pembelajaran otomatis, baik itu untuk *neural networks*, *decision trees*, maupun model-model lain yang lebih kompleks. Keunggulan TensorFlow terletak pada kemampuannya untuk menjalankan model di berbagai platform, dari perangkat mobile hingga server skala besar, serta dukungan ekosistem yang luas yang mencakup berbagai alat dan pustaka tambahan yang mempermudah pengembangan model machine learning yang efisien dan efektif [14].

2.6. MobileNetV2

MobileNetV2 adalah arsitektur *Convolutional Neural Network* yang dirancang khusus untuk mengurangi kebutuhan komputasi yang tinggi dan efisiensi sumber daya, sehingga cocok untuk perangkat dengan kapasitas terbatas seperti smartphone. Arsitektur ini berbeda dari CNN konvensional dengan menggunakan lapisan konvolusi yang disesuaikan dengan ketebalan input gambar, membagi konvolusi menjadi dua tahap: *depthwise* dan *pointwise* [15]. MobileNetV2 juga memperkenalkan dua fitur baru, yaitu *inverted residuals* dan linear *bottlenecks*, yang meningkatkan efisiensi komputasi tanpa mengorbankan akurasi. Penelitian menunjukkan bahwa penggunaan optimizer tipe ADAM dengan teknik data augmentation pada arsitektur MobileNetV2 menghasilkan tingkat akurasi yang tinggi selama proses pelatihan dan pengujian. Gambar terkait menggambarkan arsitektur MobileNetV2.




Gambar 2. Cara kerja MobileNetV2

3. METODE PENELITIAN

3.1. Rancangan Penelitian

Penelitian ini dilakukan dengan langkah-langkah berikut: pengumpulan dataset, preprocessing data, pengembangan model, pelatihan dan evaluasi model.



Gambar 3. Rancangan penelitian

3.2. Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini mencakup gambar-gambar bentuk tangan yang dibagi menjadi dua set, yaitu dataset *training* dan dataset *testing*. Sumber data berasal dari dataset publik yang tersedia di Kaggle.

Total terdapat 11.470 gambar, dengan 9.169 gambar digunakan untuk dataset *training* dan 2.301 gambar digunakan untuk dataset *testing*. Pembagian dataset ini dilakukan dengan rasio sekitar 80% untuk *training* dan 20% untuk *testing* untuk memastikan bahwa model memiliki cukup data untuk dilatih dan diuji, serta untuk menghindari *overfitting* dan memastikan generalisasi yang baik.



Gambar 4. Sampel gambar

3.3. Augmentasi Data

Objek *ImageDataGenerator* digunakan untuk menghasilkan augmented data yang diperlukan dalam pelatihan model *Convolutional Neural Network* untuk pengenalan pola bahasa isyarat. *ImageDataGenerator* menyediakan berbagai teknik augmentasi data seperti rotasi, pergeseran, zoom, dan pembalikan gambar, yang membantu model untuk belajar dari variasi yang lebih besar dalam dataset tanpa memerlukan gambar tambahan.

Selain itu, *ImageDataGenerator* juga memungkinkan normalisasi data dengan mereskalasi nilai piksel gambar, yang umumnya dilakukan untuk mempercepat konvergensi dan menghindari masalah yang terkait dengan rentang nilai piksel yang besar atau kecil.

Dengan menggunakan *ImageDataGenerator*, program dapat menciptakan generator data untuk pelatihan dan validasi model CNN dengan batch data yang dioptimalkan dan diberi label. Ini mempercepat proses pelatihan model, sambil meningkatkan kinerja dan generalisasi model dalam mengenali pola pada gambar bahasa isyarat.

Dataset ini terdiri dari total 11.470 gambar, dengan 9.169 gambar digunakan untuk *training* dan 2.301 gambar digunakan untuk *validation*. Setiap gambar diklasifikasikan ke dalam 26 kelas berbeda, dan augmentasi hanya diterapkan pada dataset *training* untuk memastikan evaluasi model dilakukan pada data yang representatif terhadap kondisi sebenarnya.

Dengan demikian, *ImageDataGenerator* memainkan peran kunci dalam memperluas dataset dan meningkatkan efisiensi pelatihan model dalam pengenalan pola pada gambar-gambar bahasa isyarat.

3.4. Arsitektur Model

Pada pembuatan program pendeteksi bahasa isyarat ini menggunakan arsitektur model *Convolutional Neural Network* berbasis MobileNetV2 untuk mengenali pola pada gambar bahasa isyarat. MobileNetV2 dipilih karena efisiensinya dalam mengelola sumber daya komputasi, sehingga sangat cocok untuk pengenalan pola pada gambar bahasa isyarat dengan dataset yang relatif besar.

Model dasar yang digunakan adalah MobileNetV2 yang telah diinisialisasi dengan bobot dari model yang dilatih pada dataset ImageNet. MobileNetV2 terdiri dari beberapa lapisan konvolusi dan lapisan *pooling* yang bertujuan untuk mengekstrak fitur-fitur penting dari gambar. CNN, seperti MobileNetV2, digunakan untuk mengenali pola pada gambar bahasa isyarat dengan lebih baik karena dapat memahami hubungan spasial antara piksel-piksel gambar. Dalam penelitian ini, lapisan-lapisan pada model dasar dibekukan (*trainable=False*), sehingga bobot-bobotnya tidak diperbarui selama pelatihan untuk mengurangi beban komputasi dan mempercepat proses pelatihan.

```
base_model = MobileNetV2(weights='imagenet', include_top=False, input_shape=(INPUT_SIZE[0], INPUT_SIZE[1], 3))
base_model.trainable = False
```

Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/mobilenet_v2/mobilenet_v2_weights_tf_dim_ordering_tf_kernels_1.0_224_no_top.h5
9406464/9406464 [=====] - 1s 0us/step

Gambar 5. MobileNetV2

Setelah model dasar MobileNetV2, beberapa lapisan kustom ditambahkan untuk menyesuaikan model dengan tugas pengenalan bahasa isyarat. Lapisan-lapisan ini meliputi:

- GlobalAveragePooling2D untuk Mengurangi dimensi data keluaran dari model dasar.
- Dense(512, activation='relu') untuk Lapisan kepadatan tinggi dengan 512 neuron dan fungsi aktivasi ReLU.
- Dense(256, activation='relu') untuk Lapisan kepadatan tinggi dengan 256 neuron dan fungsi aktivasi ReLU.
- Dense(128, activation='relu') untuk Lapisan kepadatan tinggi dengan 128 neuron dan fungsi aktivasi ReLU.
- Dense(26, activation='softmax') untuk Lapisan keluaran dengan 26 neuron dan fungsi aktivasi softmax, sesuai dengan jumlah kelas dalam dataset.

```
base_model = MobileNetV2(weights='imagenet', include_top=False)

x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dense(512, activation='relu')(x)
x = Dense(256, activation='relu')(x)
x = Dense(128, activation='relu')(x)
preds = Dense(26, activation='softmax')(x)

model = Model(inputs=base_model.input, outputs=preds)
```

Gambar 6. Arsitektur model

3.5. Pelatihan Model

Setelah melatih model *Convolutional Neural Network* (CNN) untuk pengenalan pola pada gambar bahasa isyarat, dilakukan proses evaluasi dengan menggunakan dua strategi. Pertama, model dilatih selama 10 *epochs* dengan optimizer Adam dan fungsi *loss categorical crossentropy*. Hasilnya menunjukkan peningkatan dari awal dengan akurasi *training* mencapai 93.93% dan akurasi validasi sebesar 94.61%.

Selanjutnya, untuk meningkatkan akurasi lebih lanjut, digunakan strategi *early stopping* dengan menghentikan pelatihan saat mencapai akurasi tertentu. Model dilatih tambahan 10 *epochs* dengan *learning rate* yang lebih rendah ($1e-5$) dan dihentikan saat akurasi mencapai 98%. Hasilnya menunjukkan peningkatan akurasi model, mencapai 97.82% pada akhir pelatihan, dengan akurasi validasi mencapai 95.52%.

```

Epoch 11/20
287/287 [=====] - 160s 540ms/step - loss: 0.1157 - accuracy: 0.9617 - val_loss: 0.1452 - val_accuracy: 0.9508
Epoch 12/20
287/287 [=====] - 157s 540ms/step - loss: 0.0905 - accuracy: 0.9606 - val_loss: 0.1375 - val_accuracy: 0.9505
Epoch 13/20
287/287 [=====] - 155s 540ms/step - loss: 0.0905 - accuracy: 0.9719 - val_loss: 0.1350 - val_accuracy: 0.9513
Epoch 14/20
287/287 [=====] - 155s 541ms/step - loss: 0.0869 - accuracy: 0.9703 - val_loss: 0.1323 - val_accuracy: 0.9522
Epoch 15/20
287/287 [=====] - 159s 554ms/step - loss: 0.0807 - accuracy: 0.9731 - val_loss: 0.1295 - val_accuracy: 0.9531
Epoch 16/20
287/287 [=====] - 157s 540ms/step - loss: 0.0820 - accuracy: 0.9743 - val_loss: 0.1273 - val_accuracy: 0.9537
Epoch 17/20
287/287 [=====] - 161s 560ms/step - loss: 0.0789 - accuracy: 0.9764 - val_loss: 0.1228 - val_accuracy: 0.9539
Epoch 18/20
287/287 [=====] - 167s 582ms/step - loss: 0.0769 - accuracy: 0.9762 - val_loss: 0.1214 - val_accuracy: 0.9552
Epoch 19/20
287/287 [=====] - 169s 589ms/step - loss: 0.0756 - accuracy: 0.9768 - val_loss: 0.1200 - val_accuracy: 0.9557
Epoch 20/20
287/287 [=====] - 167s 582ms/step - loss: 0.0711 - accuracy: 0.9782 - val_loss: 0.1198 - val_accuracy: 0.9552

```


Gambar 7. Hasil pelatihan

Dengan pendekatan ini, model berhasil mengenali pola pada gambar bahasa isyarat dengan tingkat akurasi yang signifikan, menunjukkan kemampuan adaptasi dan generalisasi yang baik terhadap dataset yang digunakan.

4. HASIL DAN PEMBAHASAN

Model CNN yang dikembangkan berhasil mencapai akurasi yang signifikan dalam pengenalan pola pada gambar bahasa isyarat. Pada tahap pertama pelatihan, model dilatih selama 10 *epochs* dengan optimizer Adam dan mencapai akurasi *training* sebesar 93.93% serta akurasi validasi sebesar 94.61%. Ini menunjukkan bahwa model mampu mempelajari fitur-fitur dari gambar-gambar bahasa isyarat dengan baik, serta dapat mengklasifikasikan gambar-gambar tersebut dengan tingkat keakuratan yang tinggi.

Selanjutnya, *early stopping* diterapkan untuk meningkatkan akurasi lebih lanjut. Model dilatih tambahan 10 *epochs* dengan learning rate yang lebih rendah ($1e-5$) dan dihentikan pelatihannya saat mencapai akurasi *training* 97.82% dan akurasi validasi 95.52%. Pentingnya pendekatan *early stopping* juga terlihat dalam eksperimen ini, di mana penghentian pelatihan saat mencapai akurasi tertentu membantu mencegah *overfitting* dan meningkatkan generalisasi model terhadap data baru. Pendekatan ini tidak hanya meningkatkan performa model secara signifikan tetapi juga menunjukkan kemampuan adaptasi model terhadap dataset dengan efisien.




Gambar 8. Testing Model

Penggunaan arsitektur CNN dengan lapisan-lapisan konvolusi dan *max pooling* terbukti efektif dalam mengekstrak fitur-fitur penting dari gambar bahasa isyarat. Lapisan-lapisan kepadatan tinggi yang ditambahkan setelah GlobalAveragePooling2D memungkinkan model untuk memahami hubungan spasial antar fitur-fitur ini, yang penting dalam pengenalan pola yang kompleks seperti bahasa isyarat.

Hasil yang diperoleh juga konsisten, yang menunjukkan bahwa penggunaan CNN untuk tugas pengenalan pola pada gambar memiliki potensi yang besar dalam menghadapi variasi dan kompleksitas dataset. Dengan akurasi yang tinggi, model ini dapat digunakan dalam aplikasi praktis seperti teknologi bantu untuk penyandang tunanetra atau dalam sistem otomatisasi yang membutuhkan interpretasi bahasa isyarat.

Pada gambar 8 menunjukkan representasi gesture tangan untuk huruf "N" dalam bahasa isyarat alfabet. Gestur dilakukan dengan dua tangan, di mana satu tangan membentuk posisi statis dan tangan lainnya berinteraksi untuk membentuk bentuk yang menyerupai huruf "N". Pose tangan ini ditampilkan dengan jelas dan mudah dikenali, menunjukkan bahwa proses akuisisi citra dilakukan dengan baik.



Gambar 9. Confusion matrix

Pada Gambar 9 menunjukkan *confusion matrix* yang menggambarkan kinerja model klasifikasi dalam mengenali karakter alfabet A hingga Z. Berdasarkan visualisasi ini, dapat dilihat bahwa sebagian besar prediksi model cenderung terdistribusi di sepanjang diagonal utama. Hal ini mengindikasikan bahwa model mampu mengklasifikasikan banyak karakter dengan benar, sesuai label sebenarnya. Beberapa huruf yang menunjukkan performa tinggi dapat dikenali dari nilai yang relatif tinggi di diagonalnya, seperti huruf 'H', 'K', dan 'U', yang menunjukkan bahwa model memiliki akurasi yang baik dalam mengenali karakter-

karakter tersebut. Selain itu, distribusi warna biru gelap yang tampak di sepanjang diagonal utama juga menjadi indikator bahwa model sudah cukup memahami pola karakter yang dilatih.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan sistem pengenalan huruf Bahasa Isyarat Indonesia (BISINDO) menggunakan algoritma *Convolutional Neural Network* dengan pendekatan *transfer learning* berbasis arsitektur MobileNetV2. Model yang dibangun menunjukkan performa yang sangat baik dalam proses klasifikasi, dengan akurasi validasi mencapai 95.52% dan akurasi pengujian sebesar 93.33%. Penggunaan teknik augmentasi data berhasil meningkatkan keragaman data latih, sementara strategi *early stopping* mampu mencegah *overfitting* dan mempercepat proses pelatihan. Arsitektur MobileNetV2 terbukti efisien dan efektif dalam mengekstraksi fitur visual kompleks dari citra tangan, dan dapat diimplementasikan dengan baik untuk tugas klasifikasi huruf BISINDO.

Untuk pengembangan selanjutnya, disarankan agar penelitian tidak hanya terbatas pada pengenalan huruf statis, tetapi juga mencakup gestur dan kata-kata lengkap dalam BISINDO. Penambahan data untuk variasi latar belakang, pencahayaan, dan posisi tangan juga perlu dilakukan agar model dapat lebih cocok dalam situasi nyata.

DAFTAR PUSTAKA

- [1] M. A. Afandi, A. Kinanti, I. Permatasari, dan N. Y. Tarigan, "Deteksi Objek Bahasa Isyarat Alfabet BISINDO Menggunakan Deep Learning dan Arsitektur YOLO," *Techno.Com*, vol. 23, no. 2, hlm. 411–419, Mei 2024, doi: 10.62411/tc.v23i2.9889.
- [2] M. Susanty, R. Z. Fadillah, dan A. Irawan, "Model Penerjemah Bahasa Isyarat Indonesia (BISINDO) Menggunakan Pendekatan Transfer Learning," *PETIR*, vol. 15, no. 1, hlm. 1–9, Des 2021, doi: 10.33322/petir.v15i1.1289.
- [3] O. D. Nurhayati, D. Eridani, dan M. H. Tsalavin, "Sistem Isyarat Bahasa Indonesia (SIBI) Metode Convolutional Neural Network Sequential secara Real Time," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 9, no. 4, hlm. 819–828, Agu 2022, doi: 10.25126/jtiik.2022944787.
- [4] D. R. R. Putra dan R. A. Saputra, "IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK MENDETEKSI PENGGUNAAN MASKER PADA GAMBAR," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, Agu 2023, doi: 10.23960/jitet.v11i3.3286.
- [5] M. F. Naufal dan S. F. Kusuma, "Analisis Perbandingan Algoritma Machine Learning dan Deep Learning untuk Klasifikasi Citra Sistem Isyarat Bahasa Indonesia (SIBI)," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 4, hlm. 873–882, Agu 2023, doi: 10.25126/jtiik.20241046823.
- [6] L. Arisandi dan B. Satya, "Sistem Klarifikasi Bahasa Isyarat Indonesia (Bisindo) Dengan Menggunakan Algoritma Convolutional Neural Network," *Jurnal Sistem Cerdas*, vol. 5, no. 3, hlm. 135–146, Des 2022, doi: 10.37396/jsc.v5i3.262.
- [7] Suharjito, N. Thiracitta, dan H. Gunawan, "SIBI Sign Language Recognition Using Convolutional Neural Network Combined with Transfer Learning and non-trainable Parameters," *Procedia Comput Sci*, vol. 179, hlm. 72–80, 2021, doi: 10.1016/j.procs.2020.12.011.
- [8] M. Sholawati, K. Auliasari, dan FX. Ariwibisono, "PENGEMBANGAN APLIKASI PENGENALAN BAHASA ISYARAT ABJAD SIBI MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 6, no. 1, hlm. 134–144, Mar 2022, doi: 10.36040/jati.v6i1.4507.
- [9] I. B. A. Peling, I. M. P. A. Ariawan, dan G. B. Subiksa, "Deteksi Bahasa Isyarat Menggunakan Tensorflow Lite dan American Sign Language (ASL)," *Jurnal Krisnadana*, vol. 3, no. 2, hlm. 90–100, Jan 2024, doi: 10.58982/krisnadana.v3i2.534.
- [10] R. Z. Fadillah, A. Irawan, M. Susanty, dan I. Artikel, "Data Augmentasi Untuk Mengatasi Keterbatasan Data Pada Model Penerjemah Bahasa Isyarat Indonesia (BISINDO)," *Jurnal Informatika*, vol. 8, no. 2, hlm. 208–214, 2021.
- [11] Y. Heryadi dan T. Wahyono, "DASAR DASAR DEEP LEARNING DAN IMPLEMENTASINYA," 2021.
- [12] B. Raharjo, "Deep Learning dengan python," *Penerbit Yayasan Prima Agus Teknik*, hlm. 1–131, 2022.
- [13] M. E. Laily, F. N. Fajri, dan G. Q. O. Pratamasunu, "Deteksi Penggunaan Alat Pelindung Diri (APD) Untuk Keselamatan dan Kesehatan Kerja Menggunakan Metode Mask Region Convolutional Neural Network (Mask R-CNN)," *Jurnal Komputer Terapan*, vol. 8, no. 2, hlm. 279–288, 2022.
- [14] M. Chandra dan E. Pramana, "Image Recognition Menggunakan Metode Cosine Distance untuk Aplikasi Penanganan Food Waste," *Journal of Intelligent System and Computation*, vol. 4, no. 2, hlm. 77–84, Okt 2022, doi: 10.52985/insyst.v4i2.250.
- [15] F. Zaelani dan Y. Miftahuddin, "Perbandingan Metode EfficientNetB3 dan MobileNetV2 Untuk Identifikasi Jenis Buah-buahan Menggunakan Fitur Daun," *Jurnal Ilmiah Teknologi Infomasi Terapan*, vol. 9, no. 1, Des 2022, doi: 10.33197/jitter.vol9.iss1.2022.911