



Klasifikasi Abjad SIBI (Sistem Bahasa Isyarat Indonesia) menggunakan *Mediapipe* dengan metode *Deep Learning*

Muhammad Alfian Pratama¹, Muhammad Reza Erfit², Nadiya Mujahidatul Farhani³,
Ignatius Arvantya Hartono⁴, Maryamah Maryamah⁵

^{1,2,3,4,5} *Teknologi Sains Data, Universitas Airlangga*

¹ muhammad.alfian.pratama-2020@ftmm.unair.ac.id

² muhammad.reza.erfit-2020@ftmm.unair.ac.id

³ nadiya.mujahidatul.farhani-2020@ftmm.unair.ac.id

⁴ ignatius.arvantya.hartono-2020@ftmm.unair.ac.id

⁵ maryamah@ftmm.unair.ac.id

Corresponding author email: maryamah@ftmm.unair.ac.id

Abstract: General public knowledge in Indonesia regarding the Indonesian Sign Language System (SIBI) is quite low. This can prevent deaf and mute people from doing activities in public facilities. In this paper, we propose an alphabetical classification of SIBI sign language using the *mediapipe* and the *Deep Learning* method to help deaf and mute people communicate with the public. The methodology of this paper collects a dataset in the form of image data from the hand patterns of each SIBI sign language alphabet by combining a webcam with the help of the *open-cv* library to retrieve image data. With the *mediapipe*, the data is extracted from the coordinates of the landmarks in his hand and then normalized for each coordinate. Then the model is trained with a fully connected layer deep learning algorithm. The experimental results obtained an accuracy of 94.32% and a loss of 15.17% on the training data, an accuracy of 93.52% and a loss of 18.91% on the validation data, and an accuracy of 93.94% on the test data. These results show that the *mediapipe* and the deep learning fully connected layer algorithm successfully detect the right and left hands, and coordinates of landmarks according to the SIBI sign language alphabet correctly.

Keywords: Image Classification, SIBI, *Mediapipe*, *Deep Learning*, Fully Connected Layer

Abstrak: Pengetahuan masyarakat umum di Indonesia terhadap Sistem Bahasa Isyarat Indonesia (SIBI) cukup rendah. Hal ini dapat menghambat para penyandang tunarungu dan tunawicara untuk beraktivitas di fasilitas publik. Oleh karena itu, penelitian ini mengusulkan Klasifikasi abjad bahasa isyarat SIBI dengan menggunakan *mediapipe* dan metode *Deep Learning* untuk membantu para penyandang tunarungu dan tunawicara berkomunikasi dengan masyarakat umum. Metodologi yang dilakukan adalah pengumpulan dataset berupa data citra dari bentuk pola tangan setiap abjad bahasa isyarat SIBI dengan menggabungkan *webcam* dengan bantuan *library open-cv* untuk mengambil data citra. Dengan *mediapipe*, data tersebut diekstrak koordinat landmark di tangannya dan kemudian dinormalkan setiap koordinatnya. Selanjutnya model dilatih dengan algoritma *deep learning fully connected layer*. Hasil eksperimen mendapatkan akurasi sebesar 94,32% dan *loss* 15,17% pada data training, akurasi 93,52 % dan *loss* 18,91 % pada data validasi, serta akurasi sebesar 93,94% pada data tes. Hasil tersebut menunjukkan bahwa *mediapipe* dan algoritma *deep learning fully connected layer* berhasil mendeteksi tangan kanan dan kiri, koordinat *landmark* sesuai abjad bahasa isyarat SIBI dengan tepat.

Kata kunci: Klasifikasi Gambar, SIBI, *Mediapipe*, *Deep Learning*, Fully Connected Layer

I. PENDAHULUAN

Bahasa isyarat merupakan salah satu cara berkomunikasi utama bagi tunarungu kepada sesama tunarungu atau masyarakat sekitarnya [1]. Setiap negara memiliki bahasa isyarat masing-masing yang berbeda, bahkan banyak daerah yang juga memiliki bahasa ataupun dialek isyarat yang berbeda. Menurut World Federation of the Deaf, terdapat lebih dari 300 bahasa isyarat di seluruh dunia dan 70 juta tunarungu menggunakannya. SIBI merupakan kata yang memiliki makna yang sama dan sinonim diisyaratkan dengan tempat arah dan frekuensi yang sama tetapi dengan penampil yang berbeda.



Beberapa kata yang memiliki makna yang berlawanan (yang tergolong antonim) yang diisyaratkan dengan penampil dan tempat yang sama tetapi arah gerakannya berbeda [2]. SIBI yang telah disepakati menjadi salah satu sarana yang membantu komunikasi antara individu tunarungu dan tunawicara dengan masyarakat secara luas [3]. Jumlah penduduk Indonesia yang mengalami disabilitas mencapai 211.889 orang, di antaranya 6,5% (13.802 orang) adalah tunarungu, dan 2,6% (5.580 orang) adalah tunawicara [3]. Meskipun minat masyarakat Indonesia dalam mempelajari bahasa isyarat tinggi, kurangnya sumber pembelajaran Bahasa Isyarat Indonesia menjadi salah satu hambatan dalam pemahaman masyarakat terhadap bahasa isyarat. Selain itu, kurikulum pendidikan di Indonesia belum sepenuhnya mampu memenuhi kebutuhan individu tunarungu dan tunawicara [3]. Oleh karena itu, terdapat keterbatasan dalam jumlah masyarakat umum yang memiliki kemampuan dalam memahami dan menggunakan bahasa isyarat [4].

Mediapipe adalah suatu kerangka kerja yang dikembangkan oleh Google untuk membangun rangkaian proses dalam memproses data persepsi, baik itu dalam format audio maupun video. Diluncurkan pada tahun 2019, kerangka kerja ini menyediakan berbagai solusi machine learning, seperti deteksi wajah, pengenalan gerakan tangan, segmentasi rambut, pemahaman holistik, dan lain sebagainya. Informasi lebih lanjut mengenai solusi-solusi tersebut dapat ditemukan di situs web resmi *Mediapipe* [5]. *Mediapipe* dirancang bagi mereka yang ingin mengimplementasikan kecerdasan buatan kedalam aplikasi yang akan dibangun. *Mediapipe* juga memungkinkan pembangunan aplikasi *crossplatform* yang bisa berjalan di berbagai perangkat keras yang berbeda [6]. Model yang dibangun oleh pengembang Google menggunakan Tensorflow lite memfasilitasi aliran informasi yang mudah diadaptasi dan dimodifikasi melalui grafik [7]. Kerangka kerja perangkat lunak *Mediapipe* dipilih sebagai alat untuk mengembangkan sistem klasifikasi abjad bahasa isyarat ini karena *Mediapipe* memiliki fitur-fitur yang dapat digunakan untuk melakukan pengolahan data multimedia seperti video. Selain itu, *Mediapipe* juga memiliki modularitas yang tinggi, sehingga dapat dengan mudah dikembangkan untuk melakukan klasifikasi abjad bahasa isyarat Indonesia.

Beberapa penelitian pengenalan bahasa isyarat Indonesia telah dilakukan sebelumnya dengan metode dan hasil yang beragam menggunakan model Convolutional Neural Network (CNN) yang merupakan model Inflated 3D dikombinasikan dengan metode transfer learning pada Sistem Bahasa Isyarat Indonesia (SIBI) mendapatkan akurasi 97.5% [8]. Pada tahun 2021, penelitian dilakukan mengenai pengenalan bahasa isyarat. Sebagai contoh, Ilham Rizaldy Widy Putra mengembangkan sistem deteksi simbol bahasa isyarat seperti "Saya," "Kamu," "Dia," "Cinta," "Maaf," dan "Sedih" dengan menggunakan metode Convolutional Neural Network (CNN) [9]. Pada penelitian lainnya, Mohammad Farid Naufal dan timnya menggunakan metode CNN untuk mengklasifikasikan objek peragaan dalam permainan "gunting," "batu," dan "kertas," dan berhasil mencapai akurasi klasifikasi sebesar 97,66% [10]. Darmatasia juga melakukan penelitian pada tahun yang sama dengan fokus pada klasifikasi bahasa isyarat menggunakan Sistem Bahasa Isyarat Indonesia (SIBI) dan metode Gradient-CNN, dan mencapai akurasi sebesar 98% [11]. Namun, penelitian yang telah disebutkan sebelumnya memiliki batasan karena membutuhkan perangkat khusus seperti *Leap Motion Controller* atau kamera kedalaman (*depth camera*) untuk mendapatkan informasi tiga dimensi dari gestur bahasa isyarat. Dengan adanya *Mediapipe*, sebuah kerangka kerja *open source* yang dikembangkan oleh Google, rekonstruksi kerangka tangan tiga dimensi dapat dilakukan menggunakan data dua dimensi yang diperoleh dari kamera RGB biasa yang dapat secara otomatis mengklasifikasikan abjad bahasa isyarat Indonesia berdasarkan video yang diinputkan ke dalam sistem secara langsung.

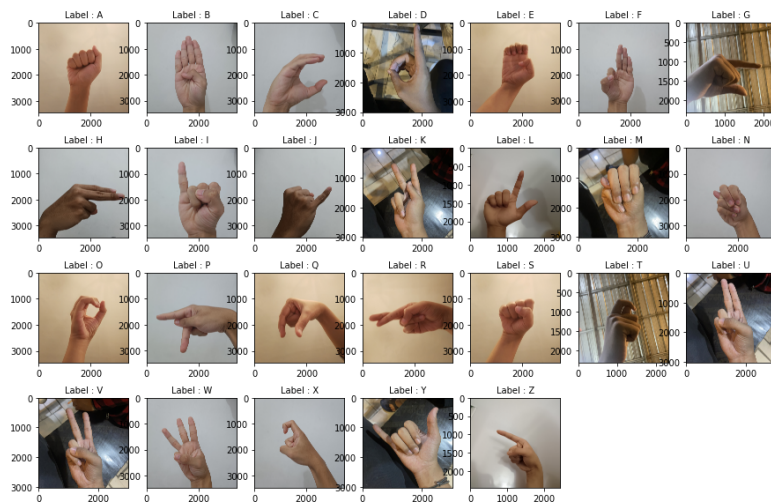
Oleh karena itu, penelitian ini mengusulkan Klasifikasi abjad bahasa isyarat SIBI dengan menggunakan *mediapipe* dan metode *Deep Learning*. Metodologi yang dilakukan adalah pengumpulan dataset berupa data citra dari bentuk pola tangan setiap abjad bahasa isyarat SIBI dengan menggabungkan webcam dengan bantuan library *open-cv* untuk mengambil data citra. Dengan *mediapipe*, data tersebut diekstrak koordinat landmark di tangannya dan kemudian dinormalkan setiap

koordinatnya. Selanjutnya model dilatih dengan algoritma *deep learning fully connected layer*. Peneliti ini dapat mempermudah para penyandang tunarungu dan tunawicara berkomunikasi dengan masyarakat umum.

II. METODE PENELITIAN

3.1 Sumber Data

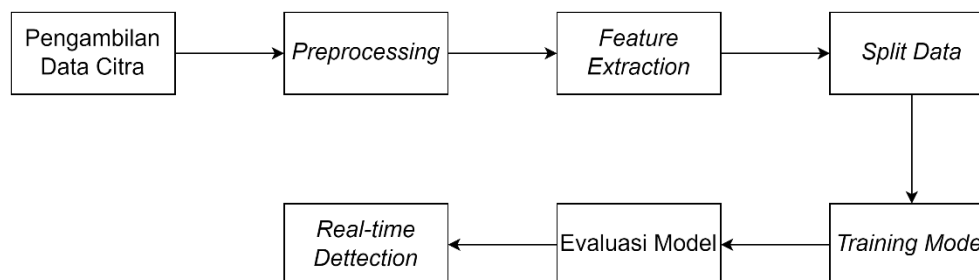
Data yang digunakan merupakan data citra abjad bahasa isyarat SIBI yang diperagakan oleh peneliti. Proses pengambilan data citra dilakukan menggunakan *smartphone* masing-masing dengan menggunakan rasio 1:1 dan melakukan pengambilan data citra sebanyak 5-6 data untuk setiap abjad bahasa isyarat SIBI, sehingga data awal sebanyak 650 data citra untuk semua abjad bahasa isyarat SIBI yang akan digunakan untuk dilakukan analisis klasifikasi. Gambar 1 merupakan tampilan dataset yang berhasil dikumpulkan.



Gambar 1. Tampilan dataset

3.2 Metodologi

Alur penelitian yang dilakukan yaitu terdiri dari beberapa alur yang diawali dengan pencarian data hingga melakukan analisis. Berikut merupakan alur dari penelitian yang dilakukan antara lain pengambilan data citra, *data preprocessing*, *feature extraction*, *split data*, *training model*, evaluasi, *real time detection*. Alur penelitian atau metodologi diawali dengan pengambilan data citra sesuai dengan yang dijelaskan pada bagian sumber data, lalu dilakukan data *preprocessing*. Pada proses data *preprocessing* dilakukan penyamaan ukuran *pixel* dan augmentasi data. Setelah dilakukan data *preprocessing*, selanjutnya adalah melakukan ekstraksi fitur menggunakan *mediapipe* khususnya menggunakan *hand solution* untuk ekstraksi koordinat *landmark* pada tangan lalu dilakukan normalisasi untuk setiap koordinatnya. Selanjutnya, adalah melakukan *splitting data* untuk *training* yang digunakan untuk melakukan pelatihan model dan *testing* untuk mengevaluasi model. Lalu, melakukan pelatihan model menggunakan algoritma *deep learning fully connected layer*. Setelah model berhasil dilatih, model digunakan untuk melakukan evaluasi model. Langkah yang terakhir adalah membuat aplikasi *real time detection* untuk melakukan klasifikasi abjad bahasa isyarat Indonesia SIBI secara *real time*.

**Gambar 2.** Metodologi penelitian


3.2.1 Data Preprocessing

Langkah data *preprocessing* yang pertama kali dilakukan adalah menyamakan ukuran *pixel* dari setiap data citra, hal ini dilakukan karena pada saat pengambilan data kamera yang digunakan berbeda-beda sehingga ukuran *pixel* untuk setiap data citra berbeda. Citra dirubah menjadi ukuran 250x250 *pixel*. Tampilan data citra setelah dilakukan penyamaan ukuran *pixel* akan terlihat data citra tidak blur dan masih jelas.

Tahap selanjutnya dari data *preprocessing* adalah melakukan augmentasi data, dikarenakan data yang dikumpulkan kurang untuk dilakukan pemodelan. Pada augmentasi data menggunakan *package ImageDataGenerator* dari *library* Tensorflow. Augmentasi dilakukan dengan memutar citra maksimal 30° khusus untuk huruf G, I, J, dan Q maksimal 15° dikarenakan memiliki pose yang relatif mirip, memperbesar citra maksimal 0.1, membalikan gambar secara horizontal, dan tingkat kecerahan antara 0.2 hingga 0.8. Masing-masing data citra akan menghasilkan 20 data citra baru hasil augmentasi. Sehingga, jumlah data akhir yang diperoleh adalah sebanyak 13.000 data.

3.2.2 Feature Extraction

Fitur ekstraksi yang digunakan adalah *mediapipe* menggunakan *hands solution*. Dengan menggunakan fitur ekstraksi ini dapat mengetahui koordinat dari masing-masing *landmark* pada tangan seperti pada Gambar 3.

**Gambar 3.** *Mediapipe hand landmark*

Hasil dari fitur ekstraksi ini akan menghasilkan 21 titik koordinat untuk setiap *landmark* tangan atau 42 titik koordinat untuk dua tangan. Setelah mengetahui masing-masing koordinat dari *landmark* tangan, perlu melakukan normalisasi nilai untuk setiap koordinat. Karena apabila tidak dilakukan normalisasi posisi dari tangan terhadap kamera akan sangat mempengaruhi koordinatnya dan nilai dari masing-masing koordinat akan sangat beragam sehingga akan sulit untuk dilakukan klasifikasi. Proses normalisasi dilakukan dengan cara mengurangi seluruh koordinat *landmark*



dengan nilai pada koordinat *landmark wrist*, hal ini dilakukan untuk menjadikan *landmark wrist* sebagai titik pusat. Selanjutnya, adalah membagi seluruh koordinat *landmark* dengan koordinat *landmark* terjauh atau nilai koordinat terbesar agar rentang nilai seluruh koordinat berada di rentang -1 hingga 1.

Dibalik kemudahan dari fitur ekstraksi menggunakan *mediapipe*, terdapat kelemahan yang ditemukan yaitu *mediapipe* tidak dapat melakukan ekstraksi fitur untuk semua data citra. Ada beberapa faktor yang menyebabkan hal ini terjadi diantaranya adalah pencahayaan dari citra yang kurang dan tidak semua jari terlihat pada gambar. Sehingga, jumlah data citra yang dapat dilakukan fitur ekstraksi menggunakan *mediapipe* ini ada sejumlah 8439 data.

3.2.3 Balancing Data

Dikarenakan *mediapipe* tidak dapat melakukan ekstraksi fitur untuk semua data citra, maka data yang didapatkan mengalami *unbalance*. Oleh karena itu, dilakukan *balancing data* menggunakan metode *oversampling* dengan algoritma *SMOTE*. Setelah dilakukan *oversampling* didapatkan jumlah data akhir sebanyak 13078 data dengan jumlah data untuk masing-masing kelas sebanyak 503 data.

3.2.4 Split Data

Sebelum melakukan pembuatan model, data harus dipisahkan untuk data *training* dan data *test* dengan jumlah data *training* sebanyak 80% jumlah data keseluruhan dan data *test* sebanyak 20% jumlah data keseluruhan. Proses pemisahan data dilakukan lagi untuk data *training* untuk mendapatkan data validasi yang digunakan pada proses pelatihan model *neural network*, dengan jumlah data *training* sebanyak 80% dari jumlah data *training* sebelumnya dan data validasi sebanyak 20% jumlah data *training*.

3.2.5 Model Deep Learning (*fully-connected layer*)

Model *Deep Learning* yang digunakan untuk klasifikasi adalah model *deep learning fully connected layer*. *Activation map* yang dihasilkan dari *feature extraction layer* masih berbentuk *multidimensional array*, sehingga mau tidak mau kita harus melakukan *reshape activation map* menjadi sebuah vektor agar bisa digunakan sebagai *input* dari *fully-connected layer*. Model yang digunakan sangat sederhana dengan 21*2 *input neuron* yang akan menjadi nilai *vector* untuk mengenali *landmark* yang sudah dijelaskan sebelumnya. Kemudian, metode *dropout* agar menonaktifkan sejumlah *edge* yang terhubung ke semua *neuron* agar tidak terjadi *overfitting* dan juga mempercepat proses *learning*. *Neuron* ini yang akan dihilangkan sementara dipilih secara acak. Pada penelitian ini, peneliti memberikan probabilitas *dropout* sebesar 0,1 dan 0,2.


Kemudian adalah proses *dense* untuk menambahkan *layer* yang *fully connected* dengan jumlah unit 512 dan 256 yang berarti jumlah node yang harus ada pada hidden layer menggunakan aktivasi relu. Aktivasi relu menjadi pilihan bagi kita karena sifatnya yang lebih berfungsi dengan baik. Selanjutnya masuk ke tahap klasifikasi dimana, menggunakan aktivasi *softmax* agar yang diklasifikasi pada input bisa sesuai dengan kategori yang telah ditentukan, yakni berjumlah 26 sesuai dengan jumlah huruf yang diklasifikasikan. Setelah arsitektur model *deep learning* telah selesai dirancang, maka didapatkan model yang terbaik yang memiliki jumlah parameter sebanyak 160.026. Untuk menyusun model agar siap untuk dilakukan proses *training*, Penelitian ini, menggunakan *adam optimizer*, *sparse categorical cross entropy* sebagai nilai *loss*, dan nilai akurasi sebagai nilai pengukurannya, untuk *fitting* modelnya ditentukan *epoch* 150 dan *batch size* 128. Metrik evaluasi yang digunakan pada penelitian ini adalah nilai akurasi.

III. HASIL DAN PEMBAHASAN


Pada penelitian ini, dilakukan evaluasi model dengan pengukuran performa akurasi dan percobaan *real-time detection*. Nilai akurasi dihitung berdasarkan jumlah data yang benar diprediksi dibandingkan dengan seluruh data dan nilai loss dihitung menggunakan fungsi loss *sparse categorical cross entropy*. Untuk *real-time detection* penelitian ini menggunakan bantuan *library open-cv* sebagai input gambar dari webcam dan *library mediapipe* untuk ekstraksi fitur dari input webcam.

4.1 Evaluasi Model

Setelah pelatihan model selesai dilakukan didapatkan akurasi sebesar 94,32% dan *loss* sebesar 15,17% pada data *training*, lalu pada data validasi akurasi sebesar 93,52% dan *loss* 18,91%. Sedangkan, pada data *test* didapatkan akurasi sebesar 93,94%. Gambar 4. merupakan visualisasikan secara interaktif nilai akurasi dan *loss* pada data *training* dan data *testing*. Dapat dilihat bahwa model cukup stabil pada masing-masing data dan tidak terjadi *overfitting*.



Gambar 4. Plot evaluasi

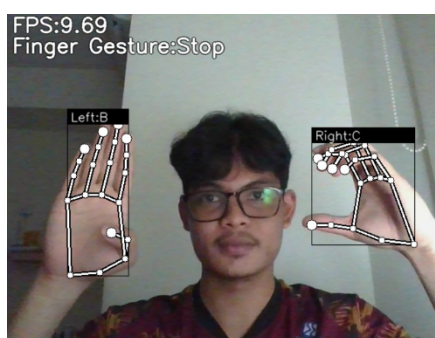


Gambar 5: Confusion matrix

Dari *confusion matrix* pada Gambar 5. dapat dilihat bahwa semua gambar sudah diklasifikasikan dengan benar kecuali pada beberapa gambar dengan index 17, 20, dan 23, yakni huruf R dan X serta U dan V karena memiliki bentuk pola tangan yang hampir mirip. Dengan akurasi 94% menunjukkan bahwa semua sudah diklasifikasikan dengan baik dan sangat akurat, Namun, ada beberapa huruf yang tidak diklasifikasikan dengan sempurna, yakni huruf dengan *index* 17, 20, dan 21 karena data memiliki bentuk pola tangan yang hampir sama. Jumlah data *test* pada masing-masing huruf dapat dilihat pada variabel support dengan jumlah total pada data test adalah 3270.

4.2 Real-Time Detection

Real time detection dilakukan dengan mengambil data citra menggunakan *webcam* dengan bantuan *library open-cv*. Lalu, untuk mendeteksi tangan beserta koordinat *landmark* menggunakan *mediapipe*. Selanjutnya, untuk model untuk klasifikasi bahasa isyarat menggunakan model yang sudah dilakukan *training* sebelumnya. Dengan menggabungkan ketiga aspek tersebut *real time detection* dapat dibangun untuk melakukan klasifikasi abjad bahasa isyarat Indonesia SIBI dengan tampilan seperti pada Gambar 10.



Gambar 10. Implementasi *real time detection*

Setelah dilakukan pengujian untuk semua abjad, saat ini sistem masih cukup kesulitan untuk memprediksi abjad dengan bentuk tangan yang hampir mirip seperti huruf X dan T, dan huruf R, U, dan V. Namun, untuk deteksi tangan kanan dan kiri beserta koordinat *landmark mediapipe* bisa melakukannya dengan sangat akurat, cepat, dan ringan.

IV. KESIMPULAN

Berdasarkan penelitian yang dilakukan, dapat disimpulkan bahwa klasifikasi abjad Bahasa Isyarat Indonesia menggunakan *Mediapipe* merupakan solusi yang efektif untuk mengenali dan mengklasifikasikan abjad Bahasa Isyarat Indonesia secara otomatis. Dalam pengembangannya, dilakukan proses pra-pemrosesan data dengan pemerataan ukuran piksel dan augmentasi data. Kemudian, dilakukan ekstraksi fitur dengan menggunakan *Mediapipe*, khususnya *hand solution*, untuk mengekstrak koordinat *landmark* pada tangan dan menormalkan setiap koordinat. Selanjutnya, dilakukan pemisahan data untuk pelatihan dan pengujian, dan dilatih menggunakan algoritma *deep learning fully connected layer*.

Dalam tahap evaluasi model didapatkan akurasi sebesar 94,32% dan loss sebesar 15,17% pada data training, lalu pada data validasi akurasi sebesar 93,52% dan loss 18,91 %. Sedangkan, pada data test didapatkan akurasi sebesar 93,94%. Saat divisualisasikan model juga cukup stabil pada masing-masing data dan tidak terjadi *overfitting*. Melalui *confusion matrix*-nya diketahui bahwa semua gambar dapat diklasifikasikan dengan baik kecuali pada huruf R dan X serta U dan V karena memiliki bentuk pola tangan yang hampir mirip. Dari *confusion matrix* tersebut juga diketahui keakuratan model



melalui nilai accuracy, precision, recall, dan f1-score. Dari 4 nilai tersebut diketahui bahwa semua sudah diklasifikasikan dengan baik dan sangat akurat kecuali huruf R, X, dan U karena bentuk pola tangan yang hampir sama. Jumlah data test pada masing-masing huruf dapat dilihat pada variabel support dengan jumlah total pada data test adalah 3270.

Secara keseluruhan, penggunaan Mediapipe dalam klasifikasi abjad Bahasa Isyarat Indonesia menunjukkan potensi yang besar untuk mengembangkan sistem yang lebih canggih dalam mengenali dan mengklasifikasikan gerakan tangan pada Bahasa Isyarat Indonesia. Penelitian ini memiliki implikasi penting untuk pengembangan teknologi dalam bidang Bahasa Isyarat Indonesia, terutama dalam membantu penyandang tuna rungu dan mempermudah komunikasi antara mereka dengan orang lain. Saran penelitian selanjutnya adalah saat pengambilan data lebih baik menggunakan fungsi *capture* pada aplikasi *real time detection* agar data yang digunakan dapat terdeteksi semua fiturnya oleh *mediapipe* dibandingkan melakukan pengambilan data secara manual menggunakan kamera pada *smartphone*.

REFERENSI

- [1] Imam Suyudi, Sudadio, Suherman. Pengenalan Bahasa Isyarat Indonesia menggunakan Mediapipe dengan Model Random Forest dan Multinomial Logistic Regression. Jurnal Ilmu Siber dan Teknologi Digital (JISTED). Vol 1, No 1, 2022, halaman 65-80. DOI: 10.35912/jisted.v1i1.1899
- [2] Hakim, Lukman, Samino, et al. Kamus Sistem Isyarat Bahasa Indonesia. Edisi Kelima. Jakarta: DIREKTORAT PEMBINAAN SEKOLAH LUAR BIASA, 2008.
- [3] Sindarto SS, Ratnawati DE, Arwani I. Klasifikasi Citra Sistem Isyarat Bahasa Indonesia (SIBI) dengan Metode Convolutional Neural Network pada Perangkat Lunak berbasis Android. Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer. 2022;6(5):2129-2138. Available from: <http://j-ptiik.ub.ac.id>
- [4] Suyudi I, Sudadio S, Suherman S. Pengenalan Bahasa Isyarat Indonesia menggunakan Mediapipe dengan Model Random Forest dan Multinomial Logistic Regression. Jurnal Ilmu Siber dan Teknologi Digital (JISTED). 2022;1(1):65-80. <https://doi.org/10.35912/jisted.v1i1.1899>
- [5] Anam N. Sistem Deteksi Simbol pada SIBI (Sistem Isyarat Bahasa Indonesia) menggunakan Mediapipe dan RESTNet-50 [Tugas Akhir]. Universitas Dinamika; 2022.
- [6] Zhang F, Bazarevsky V, Vakunov A, Tkachenka A, Sung G, Chang C-L, Grundmann M. MediaPipe hands: On-device real-time hand tracking. arXiv.org. 2020 Jun 18. Tersedia pada: <https://arxiv.org/abs/2006.10214>
- [7] Haldera A, Tayade A. Real-time Vernacular Sign Language Recognition using MediaPipe and Machine Learning. Int J Res Publ Rev. 2021;2(5):9-17. ISSN 2582-7421.
- [8] Suhartjito, Thiracitta, N., Gunawan, H. (2021). Pengenalan bahasa isyarat SIBI menggunakan convolutional neural network yang dikombinasikan dengan transfer learning dan parameter non-trainable. Procedia Computer Science, 179: 72-80.
- [9] Putra IRW. Sistem Deteksi Simbol pada SIBI (Sistem Isyarat Bahasa Indonesia) Menggunakan Convolutional Neural Network. Universitas Dinamika, 2021.
- [10] Naufal MF, et al. Klasifikasi Citra Game Batu Kertas Gunting Menggunakan Convolutional Neural Network. Techno.COM, Vol. 20, No. 1, Februari 2021, hlm. 166-174.
- [11] Darmatasia. Pengenalan Sistem Isyarat Bahasa Indonesia (SIBI) Menggunakan Gradient-Convolutional Neural Network. Jurnal Instek, Volume 6, Nomor 1, April 2021, Teknik Informatika, Universitas Islam Negeri Alauddin Makassar.