

PENDEKATAN BARU PENTERJEMAH BAHASA ISYARAT INDONESIA DINAMIS MENGGUNAKAN METODE GATE RECURRENT UNIT

Haris Setiaji*¹⁾, Asep Indra Syahyadi²⁾, Nur Afif³⁾, Ridwang⁴⁾

¹⁾ Program Studi Pendidikan Agama Islam, Fakultas Tarbiyah dan Ilmu Keguruan, Institut Agama Islam Negeri Jl. Ki Hajar Dewantara 15a Iringmulyo, Metro Timur, Kota Metro Lampung

^{2,3)} Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Alauddin Makassar Jl. H.M. Yasin Limpo No 36 Romangpolong, Kec. Sombaopu, Kab. Gowa, Sulawesi Selatan, 92118

⁴⁾ Program Studi Teknik Elektro, Fakultas Teknik, Universitas Muhammadiyah Makassar
⁴⁾Jl. Sultan Alauddin No 256

E-mail: asep@uin-alauddin.ac.id²⁾, nur.afif@uin-alauddin.ac.id³⁾, ridwang@unismuh.ac.id⁴⁾

Corresponding Author: harissetiaji@metrouniv.ac.id

Abstrak – Bahasa Isyarat Indonesia (BISINDO) dan Sistem Bahasa Isyarat Indonesia (SIBI) merupakan bentuk komunikasi yang digunakan oleh komunitas tunarungu di Indonesia. Namun, penggunaan BISINDO dinilai kurang efektif dalam sistem penterjemah bahasa isyarat karena adanya variasi gerak tubuh di setiap komunitas. Sebaliknya, SIBI dinilai lebih efektif karena merupakan adaptasi dari American Sign Language (ASL) dan telah diakui secara resmi oleh pemerintah Indonesia. Penelitian ini bertujuan untuk mengembangkan sistem penterjemah bahasa isyarat berbasis deep learning untuk mendukung komunikasi dengan komunitas tunarungu menggunakan Bahasa Isyarat Indonesia (SIBI). Metodologi penelitian ini melibatkan perolehan kumpulan data isyarat bahasa isyarat, pemrosesan awal data menggunakan perpustakaan Mediapipe, pelatihan model menggunakan Gated Recurrent Neural Networks (GRU), dan evaluasi performa model menggunakan metode Confusion Matrix. Hasil pengujian menunjukkan bahwa model yang dikembangkan berhasil mencapai tingkat akurasi sebesar 94% dalam mengklasifikasikan isyarat bahasa isyarat SIBI. Hal ini menunjukkan potensi sistem dalam membantu komunikasi dan meningkatkan aksesibilitas bagi penyandang tunarungu yang menggunakan Bahasa Isyarat Indonesia. Penelitian ini memberikan kontribusi yang signifikan terhadap perkembangan teknologi yang bertujuan untuk meningkatkan kualitas hidup dan inklusi sosial bagi komunitas tunarungu.

Kata Kunci: Bahasa Isyarat Indonesia (BISINDO), Sistem Bahasa Isyarat Indonesia (SIBI), Mediapipe, GRU.

Abstract – Indonesian Sign Language (BISINDO) and the Indonesian Sign Language System (SIBI) are forms of communication used by the deaf community in Indonesia. However, the use of BISINDO is considered less effective in the sign language translation system due to variations in body movements in each community. On the other hand, SIBI is considered more effective because it is an adaptation of American Sign Language (ASL) and has been officially recognized by the Indonesian government. This research aims to develop a deep learning-based sign language translation system to support communication with the deaf community using Indonesian Sign Language (SIBI). The research methodology involves acquiring a sign language data set, preprocessing the data using the Mediapipe library, training the model using Gated Recurrent Neural Networks (GRU), and evaluating model performance using the Confusion Matrix method. The test results show that the developed model succeeded in achieving an accuracy level of 94% in classifying SIBI sign language signs. This shows the potential of the system in assisting communication and increasing accessibility for deaf people who use Indonesian Sign Language. This research makes a significant contribution to technological developments aimed at improving the quality of life and social inclusion for the deaf community.

Keywords: Indonesian Sign Language (BISINDO), Indonesian Sign Language System (SIBI), Mediapipe, GRU.

PENDAHULUAN

Berdasarkan data statistik, diperkirakan sekitar 3,3% anak usia 5-19 tahun di Indonesia merupakan penyandang disabilitas. Pada tahun 2021, jumlah anak pada rentang usia tersebut mencapai sekitar 66,6 juta jiwa. Dengan demikian, diperkirakan terdapat sekitar 2.197.833 anak penyandang disabilitas di Indonesia dalam kelompok usia tersebut. Dari jumlah anak penyandang disabilitas tersebut, sekitar 7,03% mengalami gangguan pendengaran atau tuli, sementara sekitar 2,57% mengalami kesulitan berbicara atau bisu [1]. Data ini menunjukkan bahwa terdapat cukup banyak anak berkebutuhan khusus di Indonesia yang memerlukan perhatian dan dukungan khusus dalam pendidikan dan kehidupan sehari-hari. Ketulian merupakan kondisi di mana seseorang kehilangan kemampuan mendengar dengan baik, sehingga menghambat kemampuannya dalam memproses informasi melalui pendengaran. Hal ini dapat terjadi dengan atau tanpa penggunaan alat bantu dengar [2]. Individu penyandang tunarungu memiliki keterbatasan pendengaran yang menyulitkan mereka untuk memahami informasi yang disampaikan melalui pendengaran.

Di Indonesia, sebagian besar penyandang tunarungu menggunakan Bahasa Isyarat Indonesia (BISINDO) dibandingkan Sistem Bahasa Isyarat Indonesia (SIBI) [3]. Namun, BISINDO kurang efisien jika diterapkan pada sistem penerjemah bahasa isyarat karena setiap komunitas tunarungu di berbagai daerah memiliki gerakan BISINDO yang berbeda-beda. Berbeda dengan SIBI, yang merupakan bahasa isyarat resmi yang dibuat oleh pemerintah dan digunakan di setiap Sekolah Luar Biasa (SLB). SIBI diadaptasi dari American Sign Language (ASL) namun mengikuti kaidah tata bahasa bahasa Indonesia [4]. Misalnya, gambar di bawah ini menggambarkan perbedaan gerakan BISINDO dan SIBI yang menunjukkan seseorang sedang menonton televisi. Gambar 1 menunjukkan gerakan dalam BISINDO, sedangkan Gambar 2 menunjukkan gerakan dalam SIBI. Gerakan-gerakan ini juga akan berfungsi sebagai dataset dalam penelitian yang diusulkan.



Gambar 1 . Orang tuli menggunakan BISINDO

Karena rumitnya komunikasi antara individu dengan pendengaran normal dan penyandang tunarungu, penting untuk mencari alternatif yang dapat membantu memfasilitasi proses komunikasi bagi mereka. Salah satu solusi yang diusulkan adalah pengembangan Sign Language Recognition (SLR), yang bertujuan untuk memahami bahasa isyarat yang digunakan oleh individu tunarungu. Penelitian sebelumnya yang dilakukan oleh Gulpi Qorik Oktagalu Pratamasunu [5] berjudul “Deteksi Tangan Otomatis pada Video Percakapan Bahasa Isyarat Indonesia Menggunakan Metode Gated Recurrent Unit (GRU)” berfokus pada pengenalan tiga kelas gerak tubuh dalam Bahasa Isyarat Indonesia (BISINDO): 'halo' dan 'terima kasih', yang menghasilkan akurasi sebesar 88%. Namun, tantangan muncul karena adanya variasi gerak tubuh di BISINDO, di mana setiap komunitas memiliki gerak tubuh yang berbeda-beda. Selanjutnya, penelitian yang dilakukan oleh Ridwan dan Chairi Nur Insani [5,6] berjudul “Pengenalan Bahasa Isyarat Indonesia (SIBI) Menggunakan Leap Motion Controller (LMC) dan Algoritma Naïve Bayes Data Mining” fokus pada pengenalan abjad SIBI dalam bentuk gerakan statis dengan akurasi 95%. Namun, terdapat beberapa keterbatasan dalam penggunaan LMC, seperti biaya yang relatif mahal dan kemampuan deteksi yang terbatas pada pergerakan vertikal dalam rentang jarak tertentu, khususnya 7-50 cm.

Mengingat latar belakang penelitian-penelitian sebelumnya di atas, terdapat kebutuhan mendesak untuk mengembangkan metode yang dapat menerjemahkan Bahasa Isyarat Indonesia (SIBI) dengan lebih akurat. Salah satu pendekatan yang diusulkan adalah menggunakan metode Gated Recurrent Unit (GRU) untuk menganalisis seluruh sequence video secara detail, sehingga informasi yang diperoleh dapat lebih tepat dan akurat. Oleh karena itu, metode ini diharapkan dapat memberikan kontribusi yang signifikan dalam meningkatkan kemampuan komunikasi individu

penyandang tunarungu dan pengguna Bahasa Isyarat Indonesia.

METODE YANG DI USULKAN

Kami akan membahas langkah-langkah yang diambil dalam persiapan data dan pengembangan model untuk sistem pengenalan isyarat bahasa isyarat. Pengenalan isyarat bahasa isyarat merupakan bidang penting dalam teknologi komputer, khususnya dalam mendukung komunikasi dan aksesibilitas bagi individu dengan gangguan pendengaran. Proses pengenalan isyarat bahasa isyarat melibatkan beberapa tahapan penting, mulai dari perolehan kumpulan data yang representatif hingga pembuatan model yang akurat dan andal:

a) Dataset

Peneliti mencari beberapa individu yang mahir menggunakan Sistem Bahasa Isyarat Indonesia (SIBI). Namun, proses ini menghadapi tantangan karena tidak semua guru di Sekolah Luar Biasa (SLB) mahir dalam SIBI, dan tidak semua relawan mampu meluangkan waktu untuk merekam gerakan tangan dan pose mereka. Oleh karena itu, tiga orang relawan tuna rungu yaitu Ibu Rahmawati bersedia mengikuti penelitian tersebut. Proses akuisisi kumpulan data melibatkan perekaman langsung secara real-time menggunakan kamera, memastikan visibilitas yang jelas dari seluruh tubuh dan wajah dalam video, serta menangkap kedua tangan tanpa menutupi wajah. Video diambil di ruangan yang cukup terang untuk memastikan kualitas gambar optimal. Kamera laptop dengan resolusi HD 1280 x 720 digunakan, dan teknologi Mediapipe digunakan untuk mendeteksi landmark di setiap bagian tubuh, termasuk tangan, dan pose. Dengan langkah-langkah ini, peneliti berharap dapat mengumpulkan data yang akurat dan representatif untuk mengembangkan model pengenalan isyarat yang andal, yang akan mendukung komunikasi dan aksesibilitas bagi individu dengan gangguan pendengaran.



Gambar 2. Relawan Tunarungu

Proses akuisisi dataset melibatkan perekaman langsung menggunakan kamera laptop, di mana setiap kata yang ditandatangani direkam dengan 30 kali pengulangan untuk memastikan rentang variasi yang memadai. Selama proses perekaman, sistem secara otomatis mendeteksi titik-titik kunci/landmark pose, tangan, dan wajah di setiap frame. Ekstraksi fitur dari pose dan tangan menghasilkan 21 keypoint per tangan,

sehingga menghasilkan total 42 keypoint dari kedua tangan, sedangkan pose menghasilkan 33 keypoint [8]. Data ini kemudian diekstraksi menjadi vektor fitur yang disimpan dalam matriks n-dimensi menggunakan file numpy. Dengan metode ini, peneliti dapat memastikan bahwa dataset yang diperoleh mencakup variasi yang cukup dari setiap isyarat, yang sangat penting untuk melatih model pengenalan isyarat yang andal dan akurat.

b) Pre Processing

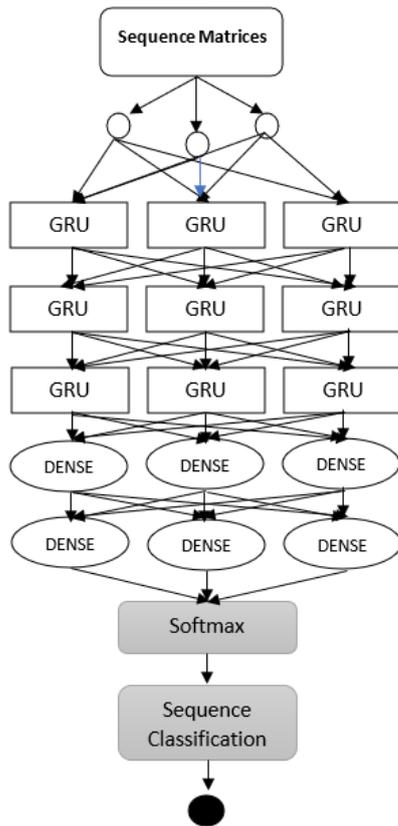
Pra-pemrosesan merupakan tahapan krusial yang dilakukan untuk menyempurnakan citra yang diperoleh dari deteksi kamera dan melakukan ekstraksi fitur. Pada penelitian ini, seluruh proses pra-pemrosesan dilakukan dengan menggunakan perpustakaan Mediapipe.

c) Deteksi Pose

Model Mediapipe digunakan untuk memprediksi pose menggunakan detektor BlazePose dan Model Landmark Berikutnya. Setelah pose berhasil dideteksi, langkah selanjutnya melibatkan pengambilan tiga potongan Region of Interest (ROI) yang menarik, masing-masing untuk kedua tangan dan wajah, seperti yang digambarkan pada Gambar 5 [11,12].

d) Ekstraksi Fitur

Langkah terakhir adalah mengekstrak fitur dari pose yang terdiri dari 33 landmark/keypoint. Ekstraksi fitur menghasilkan total 33 titik kunci dikalikan 4, sehingga menghasilkan 132 titik data. Angka 4 mewakili banyaknya variabel/parameter yang dimiliki oleh pose tersebut, seperti lebar (X), tinggi (Y), kedalaman (Z), dan visibilitas [15]. Sedangkan untuk fitur tangan, terdapat 21 titik kunci per tangan yang masing-masing terlihat pada Gambar 21. Ekstraksi fitur tangan menghasilkan total 21 titik kunci dikalikan 3 variabel (X, Y, dan Z), sehingga menghasilkan 63 titik data per tangan. Jadi, untuk kedua tangan, total data yang diekstraksi adalah 126 [16]. Untuk merancang sistem yang memanfaatkan data masukan dari pose dan tangan, data fitur yang diekstraksi diratakan menjadi satu dimensi menggunakan fungsi flatten di TensorFlow. Setelah memperoleh data ekstraksi fitur, keluaran digabungkan menggunakan fungsi String Concatenate dari pustaka Python. Penggabungan fitur pose dan tangan menghasilkan total 258 keypoint. Jumlah keypoint inilah yang akan digunakan sebagai format input ke dalam GRU (Gated Recurrent Unit).



Gambar 3. Proses Pelatihan Data dengan GRU

Proses pelatihan model, seperti yang digambarkan pada Gambar 3, melibatkan beberapa uji coba untuk menentukan jumlah epoch yang tepat agar kumpulan data dapat mencapai akurasi tinggi dan kerugian rendah. Untuk mengoptimalkan proses pelatihan, pengoptimal Adam dan fungsi kerugian crossentropy kategoris digunakan. Pengoptimal Adam umumnya digunakan karena kemampuannya mengurangi penurunan gradien stokastik secara efisien dengan estimasi momen orde pertama dan kedua yang adaptif, serta kebutuhan memorinya yang rendah. Fungsi kerugian crossentropy kategoris cocok untuk masalah klasifikasi kelas jamak karena dapat menghitung skor yang merangkum perbedaan antara distribusi probabilitas aktual dan prediksi untuk semua kelas.

Untuk mencari akurasi terbaik dari model yang dihasilkan selama proses pelatihan, dilakukan enam percobaan dengan jumlah epoch yang berbeda-beda pada setiap percobaannya. Epoch mengacu pada iterasi yang dilakukan pada seluruh kumpulan data. Eksperimen dilakukan dengan jumlah epoch yang bervariasi, yaitu 100, 150, 200, 250, dan 300, untuk memilih model dengan akurasi tertinggi. Dari enam percobaan ini, akan dipilih satu model dengan akurasi tertinggi, diukur menggunakan metrik akurasi kategoris. Jumlah fitur yang digunakan sebanyak 258 yang berasal dari gabungan fitur kedua tangan dan pose. Melalui pendekatan ini, model yang dihasilkan diharapkan dapat memberikan kinerja terbaik dalam mengenali isyarat bahasa isyarat dengan akurasi tinggi

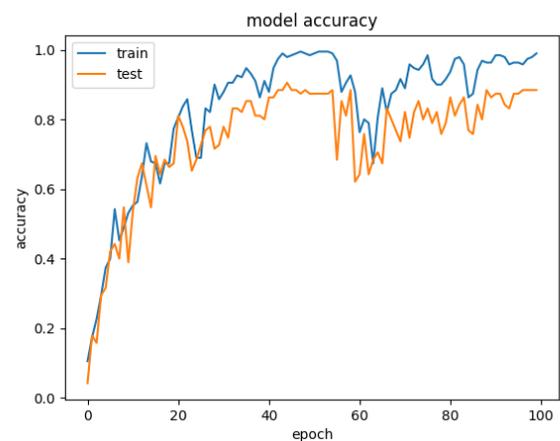
dan kerugian rendah.

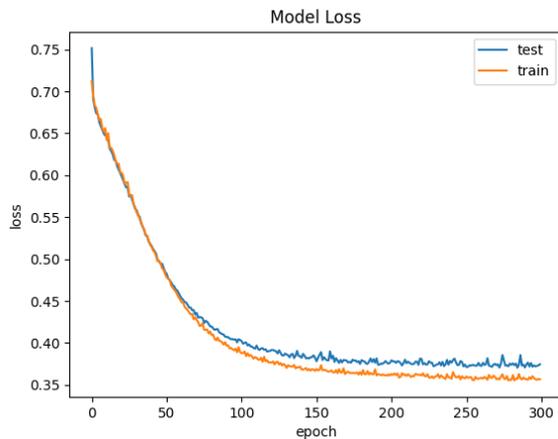
Pada percobaan dengan epoch 150-200, prosesnya hampir sama dengan percobaan epoch 100, hasil akurasi dan Loss dapat dilihat pada Tabel 1. Grafik untuk percobaan 150-250 dapat dilihat pada lampiran.

Tabel 1 Nilai Akurasi dan Loss

Tes	Masa	Nilai Akurasi	Nilai Loss
1	100	0,82	0,241
2	150	0,84	0,39
3	200	0,91	0,272
4	250	0,93	0,631
5	300	0,93	1.135

Dari Tabel 1 diperoleh nilai akurasi dan loss untuk setiap percobaan dengan jumlah epoch yang berbeda. Hasilnya menunjukkan bahwa akurasi tertinggi dicapai pada percobaan keempat dan kelima, yaitu pada epoch 250 dan 300, dengan nilai akurasi mencapai 93. Namun, terdapat perbedaan nilai loss di antara kedua percobaan ini. Meskipun akurasi mencapai puncaknya, nilai loss pada epoch 300 mencapai 1,135. Selanjutnya, dengan memperhatikan Tabel 1, perubahan nilai akurasi dan loss dapat dilihat seiring bertambahnya jumlah epoch. Dari epoch 100 hingga 250, terdapat peningkatan akurasi yang signifikan, yang menunjukkan bahwa nilai epoch yang lebih tinggi cenderung menghasilkan akurasi yang lebih baik. Namun, hal ini tidak selalu terjadi, karena penggunaan epoch yang lebih tinggi juga memerlukan waktu komputasi yang lebih besar selama proses pelatihan model. Oleh karena itu, penting untuk menemukan keseimbangan antara jumlah epoch dan performa model untuk mencapai hasil yang optimal tanpa mengorbankan efisiensi komputasi.



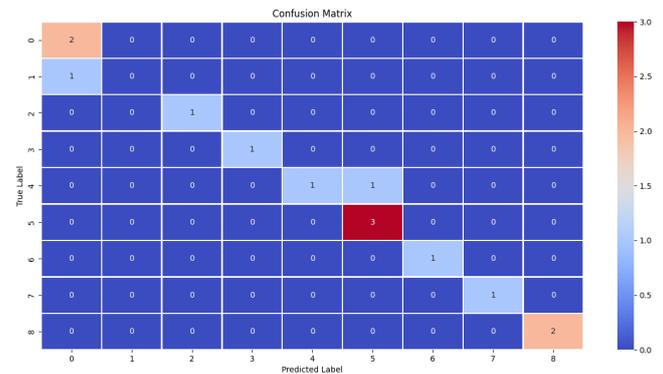


Gambar 4. Nilai Akurasi dan Loss dengan Epoch 300

Terlihat pada Gambar 5, pada percobaan epoch 220 hingga epoch 300 terjadi konvergensi dimana nilainya tidak mengalami perubahan yang signifikan. Hal ini menunjukkan bahwa model telah mencapai level stabil dan tidak memerlukan epoch tambahan. Jika akurasi sudah tinggi pada jumlah epoch yang lebih rendah, hal ini menunjukkan bahwa model yang dibangun sudah cukup akurat dan tidak memerlukan waktu komputasi yang berlebihan selama proses pelatihan dataset. Oleh karena itu disimpulkan penggunaan epoch 300 yang akurasinya mencapai 0,93 dan nilai loss 0,53 sudah memadai.

HASIL DAN PEMBAHASAN

Setelah proses akuisisi dataset, preprocessing, dan pelatihan model, Bab 3 ini akan menyajikan evaluasi komprehensif terhadap performa model yang dikembangkan. Melalui analisis yang cermat terhadap hasil eksperimen, kami akan mengungkap potensi serta keterbatasan model kami dalam mengatasi permasalahan yang diteliti. Suatu model dianggap berhasil setelah menjalani pengujian langsung dengan objek [10]. Keakuratan model kemudian dibandingkan dengan hasil validasi menggunakan metode Confusion Matrix. Dalam pengujian langsung ini dilakukan dua skenario, yaitu pertama, pengujian model yang diuji sendiri, dan kedua, pengujian lintas objek atau cross-testing antara model dengan objeknya. Berikut beberapa contoh skenario pengujian yang melibatkan 7 dari 15 kelas yang ditampilkan sebagai sampel.



Gambar 5. Confusion Matriks

Berdasarkan hasil pengujian langsung pada individu tunarungu, seperti terlihat pada Tabel 2, terdapat beberapa kata yang sulit dideteksi oleh sistem dan memiliki probabilitas deteksi yang rendah. Hal ini disebabkan oleh adanya kemiripan gerak antara kata-kata tersebut dengan kata lain, serta posisi yang kurang tepat pada saat pengambilan data untuk pelatihan. Misalnya, pada kata "Aku" dan "Ayah," isyarat untuk kata-kata ini sangat mirip, sehingga sistem mengalami kesulitan dalam membedakannya.

Setelah menguji semua kelas seperti pada Tabel 3, penting untuk dicatat bahwa jumlah tes harus sama dengan jumlah kelas untuk memastikan keakuratan pengujian. Hal ini penting karena setiap kelas perlu diuji secara menyeluruh untuk memastikan bahwa model dapat mengklasifikasikan setiap kelas yang ada dengan benar [17]. Ketidakseimbangan antara jumlah tes dan jumlah kelas dapat mengakibatkan bias dalam evaluasi kinerja model. Misalnya, jika ada kelas yang diuji hanya beberapa kali sementara kelas lain diuji lebih sering, hasil evaluasi mungkin tidak mencerminkan performa model yang sebenarnya dalam mengklasifikasikan kelas tersebut. Dengan memastikan jumlah pengujian yang seimbang, dapat dipastikan bahwa hasil evaluasi kinerja model representatif dan dapat diandalkan dalam mengevaluasi kemampuan model dalam mengklasifikasikan data secara akurat [18]. Metode yang digunakan untuk mengevaluasi kinerja model adalah matriks konfusi, yang memberikan gambaran jelas tentang seberapa baik model mengklasifikasikan setiap kelas dan memungkinkan analisis kinerja model secara mendalam. Confusion Matrix adalah tabel yang digunakan untuk mengevaluasi kinerja model klasifikasi. Ini terdiri dari empat istilah utama True Positive (TP), True Negative (TN), False Positive (FP) dan False Negative (FN). Dengan Confusion Matrix, kita dapat mengevaluasi performa model dan mengidentifikasi jenis kesalahan yang dilakukan model. Selain empat istilah utama dalam Confusion Matrix, akurasi adalah metrik yang umum digunakan untuk mengevaluasi kinerja model klasifikasi [19].

Akurasi mengukur seberapa sering model memprediksi secara keseluruhan dengan benar. Rumus untuk menghitung akurasi adalah sebagai berikut :

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

$$S_e = \frac{TP}{TP+FN} \quad (2)$$

$$S_p = \frac{TN}{TN+FP} \quad (3)$$

Tabel 1. Tabel Akurasi

	Accuracy (%)		Sensitivity (%)		Specificity (%)	
	LSTM	GRU	LSTM	GRU	LSTM	GRU
Saya	100	100	100	100	100	100
Ibu	100	100	100	100	100	100
Bapak	100	100	100	100	100	100
Play	100	100	100	100	100	100
Pukul	100	93	100	67	100	100
Dimana	93	93	50	100	100	90
Menulis	93	100	100	100	90	100

Tabel 1 menyajikan rata-rata akurasi klasifikasi tiap kelas isyarat bahasa isyarat, dengan hasil menunjukkan angka memuaskan sebesar 94%. Tingkat akurasi yang tinggi ini mencerminkan kemampuan model dalam membedakan dan mengklasifikasikan berbagai isyarat bahasa isyarat dalam Bahasa Isyarat Indonesia (SIBI) secara efektif. Keberhasilan ini menunjukkan bahwa sistem yang dikembangkan berpotensi mendukung komunikasi yang lebih efisien dan inklusif bagi komunitas tunarungu.

KESIMPULAN

Dari diskusi mengenai sistem penerjemah bahasa isyarat dan hasil pengujiannya, peneliti dapat menyimpulkan bahwa penggunaan 3 lapisan GRU dan 2 lapisan dense sudah cukup untuk mendeteksi gerakan dengan akurasi yang baik. Namun, penggunaan lapisan yang berlebihan dapat memperlambat waktu komputasi dan membuat proses pelatihan menjadi lebih menantang. Dari tes yang dilakukan, kami mengamati bahwa model mencapai tingkat akurasi yang memuaskan dalam mengklasifikasikan gerakan bahasa isyarat, dengan efektif menangani sebagian besar kelas. Namun, ada beberapa kata yang sulit dideteksi oleh sistem, mungkin karena kesamaan antara gerakan kata-kata ini dengan gerakan item kosakata lainnya, serta posisi yang tidak tepat selama proses

pengumpulan data. Meskipun demikian, model kami berhasil menunjukkan kemampuan yang baik dalam mengklasifikasikan sebagian besar gerakan bahasa isyarat, yang mengindikasikan potensi dalam membantu komunikasi dengan komunitas tunarungu. Kami percaya bahwa dengan perbaikan dan penyesuaian yang tepat, model ini dapat menjadi alat yang efektif dalam memfasilitasi komunikasi dan meningkatkan aksesibilitas bagi komunitas tunarungu. Kesimpulannya, hasil penelitian ini memberikan kontribusi berharga dalam pengembangan sistem pengenalan bahasa isyarat yang dapat digunakan dalam berbagai aplikasi untuk meningkatkan kualitas hidup dan inklusi sosial bagi individu dengan gangguan pendengaran.

DAFTAR PUSTAKA

- [1] “Pemerintah Harus Memenuhi Hak Pendidikan Inklusif bagi Penyandang Disabilitas | Kementerian Koordinator Pembangunan Manusia dan Kebudayaan.” Diakses: 13 Desember 2022. [Berani]. Tersedia pada: <https://www.kemendikpmk.go.id/pemerintah-wajib-penuhi-hak-pendidikan-inklusif-bagi-peyandang-disabilitas>
- [2] T. Handhika, RIM Zen, Murni, DP Lestari, dan I. Sari, “Pengenalan Gestur Bahasa Isyarat Indonesia (BISINDO),” *J. Phys. Conf. Ser.*, jilid. 1028, hlm. 012173, Juni 2018, doi: 10.1088/1742-6596/1028/1/012173.
- [3] RA Pranatadesta dan IS Suwardi, “Sistem Penerjemahan Bahasa Isyarat Indonesia (BISINDO) dengan ORB untuk Bahasa Bilingual,” dalam *International Conference of Artificial Intelligence and Information Technology (ICAIIIT) 2019*, Yogyakarta, Indonesia: IEEE, Mar 2019, hlm. 502–505. doi: 10.1109/ICAIIIT.2019.8834677.
- [4] M. Boulares dan M. Jemni, “Sistem penerjemahan bahasa isyarat seluler untuk komunitas tunarungu,” dalam *Proceedings of the International Cross-Disciplinary Conference on Web Accessibility*, Lyon Prancis: ACM, Apr 2012, hlm. 1–4. doi: 10.1145/2207016.2207049.
- [5] GQO Pratamasunu dan FN Fajri, “Deteksi Tangan Otomatis Pada Video Percakapan Bahasa Isyarat Indonesia Menggunakan Metode Deep Gated Recurrent Unit (GRU)”.
- [6] Fakultas Teknik Universitas Hasanuddin dan R. Ridwang, “Pengenalan Bahasa Isyarat Indonesia (SIBI) Menggunakan Leap Motion Controller dan Algoritma Data Mining Naïve

- Bayes,” *J. Insypro Inf. sistem. Proses.* , jilid. 2, tidak. 2, Oktober 2017, doi: 10.24252/insypro.v2i2.4070.
- [7] CN Insani, I. Nurtanio, dan AA Ilham, “The effect of light on Leap Motion Controller in the classification of Sign Language Translator System,” dalam *Seminar Internasional Penelitian Teknologi Informasi dan Sistem Cerdas (ISRITI) 2019* , Yogyakarta , Indonesia: IEEE, Des 2019, hlm. 296–300. doi: 10.1109/ISRITI48646.2019.9034602.
- [8] “Pipa Media.” Diakses: 13 Desember 2022. [Berani]. Tersedia pada: <https://mediapipe.dev/>
- [9] S. Adhikary, AK Talukdar, dan K. Kumar Sarma, “Sistem Berbasis Visi untuk Pengenalan Kata-kata yang digunakan dalam Bahasa Isyarat India Menggunakan MediaPipe,” dalam *Konferensi Internasional Keenam tentang Pemrosesan Informasi Gambar (ICIIP) tahun 2021* , Shimla, India: IEEE, Nov 2021, hlm. 390–394. doi: 10.1109/ICIIP53038.2021.9702551.
- [10] S. Negi, M. Garg, H. Maindola, V. Kansal, U. Jain, dan S. Bhatla, “Real-Time Human Pose Estimation: A MediaPipe and Python Approach for 3D Detection and Classification,” pada *tahun 2023 Konferensi Internasional ke-3 tentang Kemajuan Teknologi dalam Ilmu Komputasi (ICTACS)* , Tashkent, Uzbekistan: IEEE, Nov 2023, hlm. 128–133. doi: 10.1109/ICTACS59847.2023.10390506.
- [11] AM Al-Nuimi dan GJ Mohammed, “Estimasi Arah Wajah berdasarkan Landmark Mediapipe,” dalam *Konferensi Internasional ke-7 tentang Teknologi Informasi dan Matematika Kontemporer (ICCITM) 2021* , Mosul, Irak: IEEE, Agu 2021, hlm. 185–190. doi: 10.1109/ICCITM53167.2021.9677878.
- [12] MH Ismail, SA Dawwd, dan FH Ali, “Deteksi Bahasa Isyarat Arab Menggunakan Estimasi Pose Berbasis Pembelajaran Mendalam,” dalam *2nd Information Technology To Enhance e-learning and Other Application (IT-ELA)* , Bagdad, Irak: IEEE , Des 2021, hlm. 161–166. doi: 10.1109/IT-ELA52201.2021.9773404.
- [13] SS Teja Gontumukkala, Y. Sai Varun Godavarthi, BR Ravi Teja Gonugunta, dan S. Palaniswamy, “Permainan Kriket Tangan menggunakan CNN dan MediaPipe,” dalam *Konferensi Internasional ke-13 tentang Teknologi Komunikasi dan Jaringan Komputasi (ICCCNT) tahun 2022* , Kharagpur, India: IEEE, Okt 2022, hlm. 1–6. doi: 10.1109/ICCCNT54827.2022.9984411.
- [14] GKR Madrid, RGR Villanueva, dan MVC Caya, “Recognition of Dynamic Filipino Sign Language using MediaPipe and Long Short-Term Memory,” dalam *Konferensi Internasional ke-13 tentang Teknologi Komunikasi dan Jaringan Komputasi (ICCCNT) ke-13 tahun 2022* , Kharagpur, India: IEEE , Okt 2022, hlm. 1–6. doi: 10.1109/ICCCNT54827.2022.9984599.
- [15] F. Daniel Tanugraha, H. Pratikno, M. Mu1nah, dan W. Indah Kusumawati, “Pengenalan Gerakan Olahraga Berbasis (Long Short-Term Memory) Menggunakan Mediapipe,” *J. Adv. Inf. Teknologi Ind.* , jilid. 4, tidak. 1, hlm. 37–45, Mei 2022, doi: 10.52435/jaiit.v4i1.182.
- [16] VSP Bhamdipati, I. Saxena, D. Saisanthiya, dan M. Retnadhas, “Robust Intelligent Posture Estimation for an AI Gym Trainer menggunakan Mediapipe dan OpenCV,” dalam *Konferensi Internasional tentang Jaringan dan Komunikasi (ICNWC) 2023* , Chennai, India : IEEE, Apr 2023, hlm. 1–7. doi: 10.1109/ICNWC57852.2023.10127264.
- [17] “Recurrent Neural Network (RNN) dan Gated Recurrent Unit (GRU),” Fakultas Ilmu Komputer. Diakses: 16 Januari 2023. [Berani]. Tersedia pada: <https://socs.binus.ac.id/2017/02/13/rnn-dan-gru/>
- [18] G. Pala, JB Jethwani, SS Kumbhar, dan SD Patil, “Pengenalan Tanda Tangan Berbasis Pembelajaran Mesin,” dalam *Konferensi Internasional tentang Kecerdasan Buatan dan Sistem Cerdas (ICAIS) 2021* , Coimbatore, India: IEEE, Mar 2021, hlm. 356–363. doi: 10.1109/ICAIS50930.2021.9396030.
- [19] Khalis Sofi, Aswan Supriyadi Sunge, Sasmitoh Rahmad Riady, dan Antika Zahrotul Kamalia, “PERBANDINGAN ALGORITMA LINEAR REGRESION, LSTM, DAN GRU DALAM MEMPREDIKSI HARGA SAHAM DENGAN MODEL TIME SERIES,” *SEMINASTIKA* , vol. 3, tidak. 1, hlm. 39–46, November 2021, doi: 10.47002/seminastika.v3i1.275.