



PENGEMBANGAN SISTEM KLASIFIKASI GESTUR BAHASA ISYARAT BERBASIS GAMIFIKASI ADAPTIF MENGUNAKAN SVM DENGAN MEKANISME ADAPTIVE GESTURE DIFFICULTY LEVELING (AGDL)

Reno Nilam Sari¹, Dedy Irfan², Syafrijon³, Randi Proska Sandra⁴

¹Program Studi Informatika, Fakultas Teknik, Universitas Negeri Padang, Indonesia

^{2,3,4}Universitas Negeri Padang, Indonesia

Correspondence: E-mail: dedy_irf@ft.unp.ac.id

ABSTRACT

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi gestur Sistem Isyarat Bahasa Indonesia (SIBI) berbasis peramban web yang interaktif guna memfasilitasi pembelajaran inklusif bagi komunitas Tuli. Pendekatan yang digunakan mengintegrasikan ekstraksi *landmark* MediaPipe dan algoritma *Support Vector Machine* (SVM) yang dieksekusi murni di sisi klien (*client-side inference*) menggunakan format ONNX, serta dilengkapi dengan mekanisme *Adaptive Gesture Difficulty Leveling* (AGDL). Hasil evaluasi menunjukkan model SVM mencapai akurasi sebesar 98,92% dalam mengenali 36 kelas gestur, dengan skor *System Usability Scale* (SUS) mencapai 86,0 (*Best Imaginable*). Implementasi arsitektur *client-side* terbukti mampu mengeliminasi latensi *server* dan mengamankan privasi data pengguna, sementara penerapan elemen gamifikasi adaptif secara dinamis berhasil mempertahankan keterlibatan pengguna pada zona *flow*. Dampak dari inovasi ini adalah terciptanya solusi produk edukasi teknologi (*EdTech*) yang skalabel, aman, dan dapat diadopsi secara luas untuk menjembatani kesenjangan komunikasi tanpa memerlukan infrastruktur *cloud* yang berbiaya tinggi.

ARTICLE INFO

Article History:

Submitted/Received 28 April 2026

First Revised 29 April 2026

Accepted 30 April 2026

First Available online 30 April 2026

Publication Date 30 April 2026

Keyword:

Client-Side Inference, EdTech, Gamification, MediaPipe, SIBI, Support Vector Machine.

1. INTRODUCTION

Kemampuan berkomunikasi menggunakan bahasa isyarat, khususnya Sistem Isyarat Bahasa Indonesia (SIBI), merupakan elemen fundamental untuk menciptakan ruang interaksi sosial yang inklusif bagi komunitas Tuli di Indonesia (Nugraheni et al., 2023). Standarisasi pembelajaran bahasa isyarat melalui aplikasi digital secara konsisten telah terbukti mampu meningkatkan aksesibilitas secara masif (Wibowo et al., 2023). Untuk mengatasi kendala kebosanan pengguna, pendekatan gamifikasi telah dikonfirmasi secara teoretis mampu meningkatkan motivasi intrinsik pelajar (Dichev & Dicheva, 2017; Krath et al., 2021). Di era digitalisasi bisnis dan pendidikan saat ini, penyediaan fasilitas pembelajaran bahasa isyarat yang mudah diakses menjadi sebuah urgensi. Namun, media pembelajaran SIBI konvensional, seperti modul cetak atau video satu arah, sering kali bersifat pasif. Pendekatan statis ini menghambat proses evaluasi mandiri secara seketika (*real-time*) dan berimplikasi pada tingginya tingkat kebosanan serta rendahnya retensi motivasi pelajar (Paudyal et al., 2020).

Inovasi teknologi *Computer Vision* (CV) dan kecerdasan buatan telah membuka peluang baru untuk evaluasi gestur yang interaktif. Kendati demikian, sebagian besar solusi pengenalan isyarat yang beredar di industri saat ini bergantung pada arsitektur komputasi awan (*cloud inference*). Ketergantungan ini memunculkan tiga tantangan utama: (1) latensi jaringan yang mengganggu responsivitas sistem; (2) biaya operasional *server* yang tinggi, sehingga membatasi skalabilitas produk secara komersial; dan (3) risiko pelanggaran privasi, mengingat data visual pengguna harus ditransmisikan ke jaringan eksternal (Wang et al., 2025).

Beberapa literatur terdahulu telah berupaya mengatasi tantangan akurasi dalam pengenalan gestur. Bora et al. (2023) menggunakan pendekatan *deep learning* berbasis *Convolutional Neural Network* (CNN) untuk menerjemahkan bahasa isyarat. Meskipun akurat, arsitektur tersebut menuntut spesifikasi perangkat keras yang tinggi. Sebagai alternatif yang lebih efisien, algoritma klasik seperti *Support Vector Machine* (SVM) terbukti sangat optimal saat diintegrasikan dengan metode ekstraksi fitur *skeletal point detection* dari MediaPipe, menawarkan komputasi yang jauh lebih ringan untuk mengenali gestur statis (Saleh, 2025). Akan tetapi, efisiensi algoritma ini belum dieksploitasi secara maksimal dalam ekosistem peramban web murni (*web-based*) sebagai produk teknologi pendidikan (*EdTech*). Selain itu, sistem yang ada saat ini belum mengadopsi mekanisme gamifikasi cerdas untuk menyesuaikan tingkat kesulitan secara personal guna menjaga pengguna tetap berada dalam zona fokus atau *flow* (Legaki et al., 2020).


Berdasarkan celah riset tersebut, penelitian ini bertujuan untuk merancang dan mengembangkan platform aplikasi web pembelajaran SIBI yang interaktif, personal, dan efisien secara komputasi. Inovasi utama yang ditawarkan adalah arsitektur *client-side inference* yang menjalankan kompilasi model SVM dan MediaPipe melalui ONNX Runtime langsung pada peramban pengguna. Lebih jauh, sistem ini diintegrasikan dengan mekanisme *Adaptive Gesture Difficulty Leveling* (AGDL). Algoritma AGDL secara dinamis mengevaluasi *confidence score* dari prediksi SVM dan batasan waktu (*response time*) dari interaksi pengguna untuk menyesuaikan tingkat kesulitan materi. Melalui perpaduan teknologi ini, diharapkan tercipta solusi bisnis digital di sektor pendidikan yang responsif, menjaga privasi pengguna secara absolut, dan secara psikologis mampu meningkatkan motivasi belajar isyarat secara mandiri.

2. METHODS

Penelitian ini mengadopsi metodologi pengembangan perangkat lunak *Agile* dengan pendekatan iteratif dan inkremental. Model ini dipilih karena pengembangan sistem berbasis kecerdasan buatan (AI) memerlukan siklus penyetelan (*tuning*) yang berulang untuk mencapai tingkat akurasi dan responsivitas yang optimal (Romão et al., 2025). Secara sistematis, tahapan penelitian diklasifikasikan ke dalam empat fase utama: akuisisi data, perancangan model AI, pengembangan arsitektur *client-side*, dan integrasi mekanisme gamifikasi adaptif.

2.1 Data Acquisition and Preprocessing

Dataset yang digunakan mencakup 36 kelas gestur statis SIBI, yang terdiri dari alfabet (A-Z) dan 10 kata dasar. Proses pengolahan data dimulai dengan ekstraksi 21 titik koordinat skeletal tangan menggunakan kerangka kerja MediaPipe Hands (Lugaresi et al., 2019; Zhang et al., 2020). Guna memastikan model bersifat *robust* terhadap variasi jarak dan posisi tangan, dilakukan normalisasi koordinat relatif terhadap *wrist point*. Alur pemrosesan data dari input visual hingga menjadi fitur numerik diilustrasikan pada Gambar 1.



Gambar 1. Pipeline Ekstraksi Fitur dan Klasifikasi

Gambar 1 menunjukkan transformasi citra mentah menjadi titik skeletal 3D, proses normalisasi, hingga data siap diumpungkan ke pengklasifikasi.

2.2 Support Vector Machine and ONNX Conversion

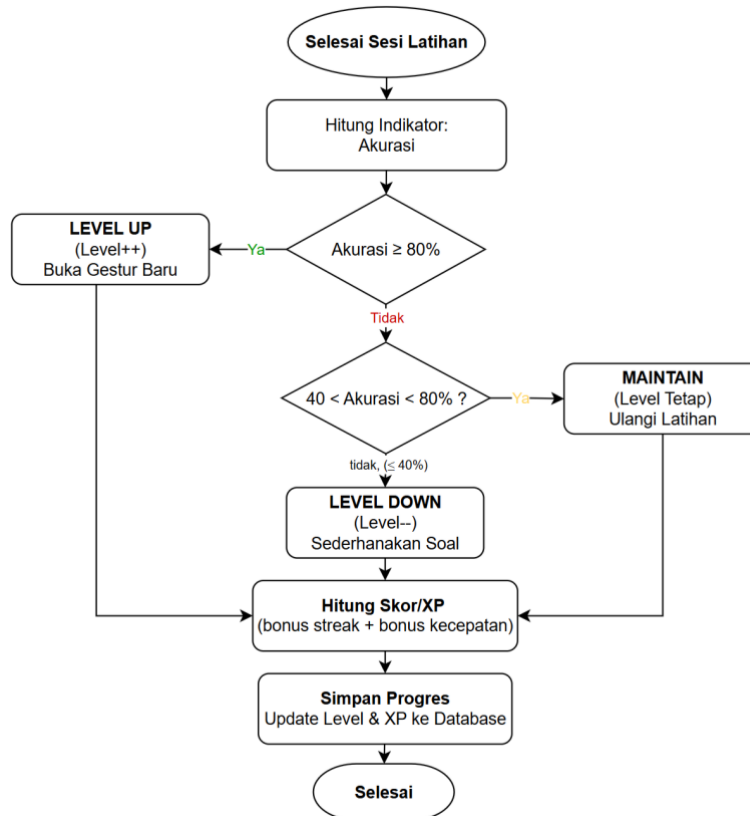
Algoritma *Support Vector Machine* (SVM) dengan kernel *Radial Basis Function* (RBF) diimplementasikan karena efisiensinya yang terbukti tangguh dalam mengklasifikasikan fitur geometris bahasa isyarat (Niswati et al., 2021; Sruthi & Sasikala, 2021). Pasca pencapaian akurasi target pada fase pelatihan, model dikonversi ke format *Open Neural Network Exchange* (ONNX) (Jin et al., 2020). Hal ini memungkinkan eksekusi model secara lokal pada peramban melalui ONNX Runtime, yang secara signifikan mereduksi latensi dibandingkan pendekatan berbasis *cloud* (Wang et al., 2025). Kinerja SVM dalam memproses data berdimensi tinggi, seperti koordinat skeletal MediaPipe, sangat dipengaruhi oleh jumlah variasi sampel selama fase pelatihan (Kupidura et al., 2024). Penggunaan kernel RBF memungkinkan sistem untuk menciptakan garis pemisah non-linear yang sangat fleksibel namun tetap efisien saat dikonversi ke format ONNX untuk kebutuhan inferensi web.

2.3 Adaptive Gesture Difficulty Leveling (AGDL)

Inovasi utama penelitian ini terletak pada mekanisme *Adaptive Gesture Difficulty Leveling* (AGDL). Sistem melakukan evaluasi performa pengguna secara dinamis pada setiap akhir sesi latihan. Algoritma AGDL menggunakan metrik akurasi dari *confidence score* SVM sebagai parameter fundamental dalam gerbang keputusan adaptif. Logika penyesuaian level ini beroperasi melalui tiga ambang batas utama: (1) Jika tingkat akurasi mencapai $\geq 80\%$, sistem

memicu *Level Up* untuk membuka akses gestur baru; (2) Jika akurasi berada pada rentang moderat ($40\% < \text{akurasi} < 80\%$), sistem akan mempertahankan tingkat kesulitan (*Maintain*); serta (3) Jika akurasi $\leq 40\%$, sistem memicu *Level Down* guna menyederhanakan instruksi pembelajaran.

Setelah keputusan level dieksekusi, sistem mengkalkulasi perolehan *Experience Points* (XP) dengan mengintegrasikan bonus konsistensi (*streak*) dan bonus kecepatan, yang kemudian disinkronkan secara atomik ke dalam *database* Firestore. Detail operasional alur ini dijabarkan pada Gambar 2.

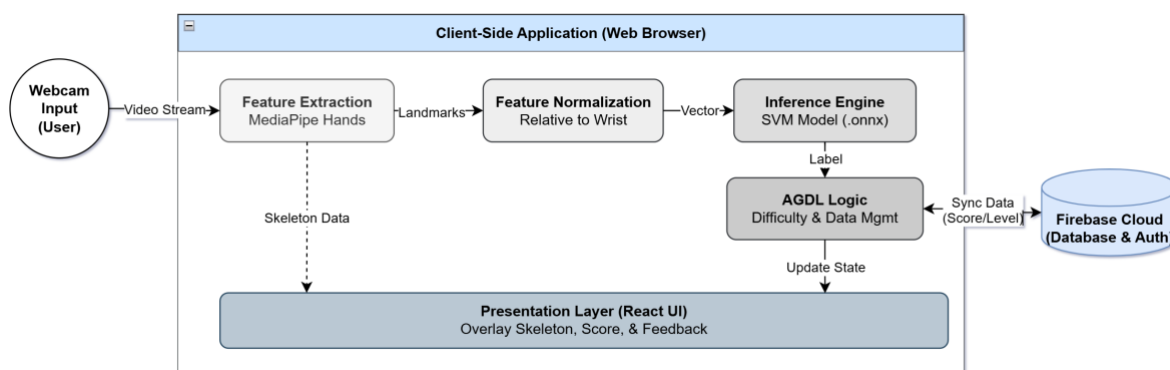


Gambar 2. Diagram Alir Logika Penyesuaian Tingkat Kesulitan (AGDL)

Gambar 2 merinci alur logika algoritma AGDL dalam menentukan transisi tingkat kesulitan berdasarkan evaluasi ambang batas akurasi pengguna.

2.4 System Architecture and Data Schema

Aplikasi dikembangkan dengan memanfaatkan *library* React.js untuk membangun antarmuka web yang responsif secara *real-time* (Aggarwal & Verma, 2022). Pendekatan komputasi cerdas yang ringan (*lightweight deep learning*) sangat dibutuhkan untuk memastikan aplikasi dapat berjalan mulus pada lingkungan dengan sumber daya perangkat keras yang terbatas (Liu et al., 2024). Selain itu, desain alur penggunaan (*use case*) sistem dirancang menggunakan metodologi terstruktur agar interaksi antara pengguna dan mesin inferensi berjalan efisien (Ostermann et al., 2023). Penyimpanan data dilakukan menggunakan Firebase Firestore dengan skema NoSQL yang memisahkan antara data profil pengguna (*user profiles*), sesi latihan (*practice sessions*), dan detail percobaan (*practice attempts*). Struktur data ini dirancang untuk memfasilitasi analisis performa granular sekaligus mendukung sinkronisasi data yang skalabel dalam ekosistem pendidikan digital. Arsitektur sistem secara komprehensif ditunjukkan pada Gambar 3.

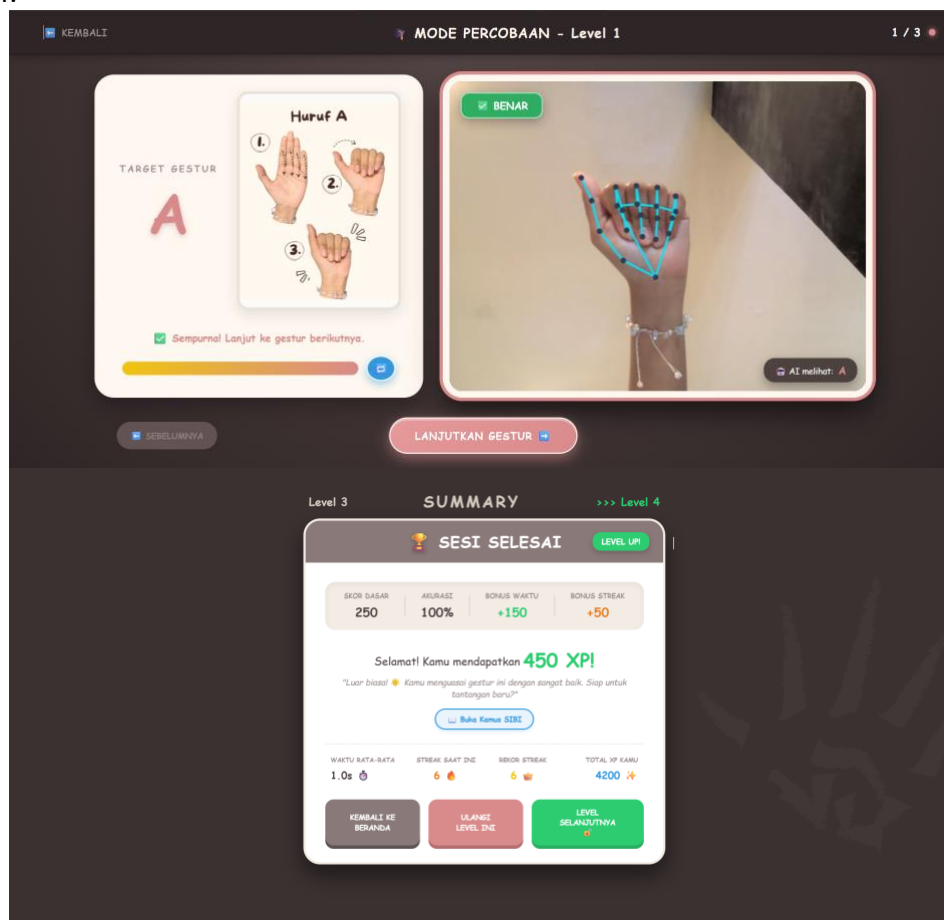


Gambar 3. Arsitektur Sistem Klasifikasi Gestur SIBI

Gambar 3 mengilustrasikan interaksi antara komponen antarmuka, library MediaPipe, mesin inferensi ONNX, dan database Firebase dalam ekosistem peramban web.

3. RESULTS AND DISCUSSION

Secara operasional, sistem SIBI Master telah berhasil diimplementasikan sebagai aplikasi web interaktif. Antarmuka sistem dirancang dengan mengedepankan prinsip *User-Centered Design*, di mana area pembelajaran visual disandingkan secara *real-time* dengan elemen umpan balik gamifikasi (seperti indikator *streak* dan perolehan XP). Tampilan implementasi antarmuka saat sistem mendeteksi gestur dan memicu mekanisme adaptif ditunjukkan pada Gambar 4.



Gambar 4. Implementasi Antarmuka Deteksi Gestur dan Umpan Balik Gamifikasi

Hasil penelitian dan pembahasan lebih lanjut mencakup analisis komprehensif terhadap performa teknis algoritma, efisiensi operasional pada sisi klien (*client-side*), serta tingkat ketergunaan sistem berdasarkan evaluasi pengalaman pengguna.

3.1 Model Accuracy and Classification Performance

Pengujian model SVM dilakukan terhadap 36 kelas gestur statis SIBI. Hasil pengujian menggunakan *confusion matrix* (Grandini et al., 2020) menunjukkan bahwa sistem mencapai tingkat akurasi presisi sebesar 98,92% (berhasil mengklasifikasikan 730 prediksi benar dari total 738 data uji). Performa ini didorong oleh optimalisasi ekstraksi fitur MediaPipe dalam memetakan koordinat skeletal secara presisi, serta pemilihan kernel RBF pada SVM yang efektif dalam mengklasifikasikan ruang fitur gestur dengan kemiripan visual tinggi (seperti huruf 'U' dan 'V'). Data rekapitulasi hasil pengujian akurasi untuk setiap kelas gestur disajikan secara mendetail pada Tabel 1.

Tabel 1. Hasil Pengujian Akurasi Model SVM

Kelas Gestur	Precision	Recall	F1-Score	Support (Jumlah Data)
A	1.0000	1.0000	1.0000	16
B	1.0000	1.0000	1.0000	18
C	1.0000	1.0000	1.0000	24
D	1.0000	1.0000	1.0000	15
E	1.0000	1.0000	1.0000	29
F	1.0000	1.0000	1.0000	22
G	0.8235	1.0000	0.9032	14
H	1.0000	0.9524	0.9756	21
I	1.0000	1.0000	1.0000	21
J	1.0000	1.0000	1.0000	20
K	1.0000	1.0000	1.0000	22
L	1.0000	1.0000	1.0000	24
M	1.0000	1.0000	1.0000	22
N	1.0000	1.0000	1.0000	22
O	1.0000	1.0000	1.0000	18
P	1.0000	1.0000	1.0000	21
Q	1.0000	1.0000	1.0000	27
R	1.0000	1.0000	1.0000	22
S	1.0000	1.0000	1.0000	18
T	1.0000	1.0000	1.0000	25
U	0.8400	1.0000	0.9130	21
V	1.0000	0.8333	0.9091	24
W	1.0000	1.0000	1.0000	16
X	1.0000	1.0000	1.0000	20
Y	1.0000	1.0000	1.0000	22
Z	0.9524	1.0000	0.9756	20
Halo	1.0000	1.0000	1.0000	24
bagus	1.0000	1.0000	1.0000	6
bantu	1.0000	1.0000	1.0000	13
cinta	1.0000	0.9412	0.9697	17
maaf	1.0000	1.0000	1.0000	26
nama	1.0000	0.8889	0.9412	18
rumah	1.0000	1.0000	1.0000	24
saya	1.0000	1.0000	1.0000	28
sempurna	1.0000	1.0000	1.0000	16
teman	1.0000	1.0000	1.0000	22
Akurasi (Overall)				0.9892

Berdasarkan Tabel 1, tingkat kesalahan klasifikasi (*misclassification*) berhasil ditekan pada angka yang sangat minimal, membuktikan keandalan algoritma dalam membedakan fitur mikro antar kelas isyarat tangan.

3.2 Performance and Latency Analysis

Salah satu indikator utama keberhasilan sistem ini sebagai produk digital (*EdTech*) adalah efisiensi operasionalnya. Penggunaan arsitektur *client-side inference* dengan format ONNX memungkinkan model dieksekusi langsung pada peramban pengguna secara mandiri. Pendekatan ini secara inheren mengeliminasi *bottleneck* jaringan dan latensi yang umumnya menjadi kendala utama pada sistem berbasis *cloud*. Efisiensi arsitektural ini sangat krusial dalam konteks bisnis digital karena mampu mereduksi beban biaya infrastruktur *server* secara drastis, sekaligus memberikan jaminan mutlak terhadap privasi pengguna karena tidak ada transmisi data visual yang dikirim ke jaringan eksternal (Choi et al., 2020; Wang et al., 2025).

3.3 Usability Evaluation (SUS)

Ketergunaan sistem dievaluasi secara komprehensif dengan melibatkan 15 responden menggunakan instrumen standar *System Usability Scale* (SUS) sebagai bagian dari pendekatan *User-Centered Design*. Instrumen ini dipilih untuk mengukur sejauh mana fungsionalitas aplikasi dapat diterima oleh target pengguna akhir dari berbagai latar belakang program studi. Rekapitulasi skor dari seluruh responden dirangkum dalam Tabel 2.

Tabel 2. Rekapitulasi Skor System Usability Scale (SUS)

Responden	Program Studi	Total Skor Mentah	Skor Akhir SUS
R1	Informatika	38	95,0
R2	Informatika	40	100,0
R3	Desain Komunikasi Visual (DKV)	40	100,0
R4	Informatika	35	87,5
R5	Informatika	32	80,0
R6	Pend. Bahasa Indonesia	32	80,0
R7	Psikologi	28	70,0
R8	Bimbingan dan Konseling	27	67,5
R9	Psikologi	33	82,5
R10	Informatika	37	92,5
R11	Informatika	31	77,5
R12	Informatika	38	95,0
R13	Informatika	25	62,5
R14	Informatika	40	100,0
R15	Informatika	40	100,0
Rata-Rata Keseluruhan			86,0

Sebagaimana ditunjukkan pada Tabel 2, sistem memperoleh skor rata-rata SUS sebesar 86,0. Nilai ini secara kualitatif dikategorikan sebagai *Excellent* (Sangat Baik), yang mengindikasikan tingkat kepuasan dan penerimaan pengguna yang tinggi terhadap aplikasi. Skor yang konsisten di berbagai latar belakang demografi ini menegaskan bahwa antarmuka pengguna rancangan ini sangat intuitif untuk dinavigasi secara mandiri, serta mekanisme gamifikasi adaptifnya berhasil memandu pengguna tanpa memerlukan instruksi teknis yang rumit.

3.4 Discussion

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa integrasi SVM, MediaPipe, dan mekanisme AGDL menciptakan sinergi yang sangat optimal sebagai media pembelajaran bahasa isyarat. Penggunaan *client-side inference* berhasil menjawab tantangan besar dalam skalabilitas aplikasi pendidikan digital modern. Secara teoritis, keberhasilan AGDL dalam mempertahankan pengguna melalui gerbang keputusan akurasi 80% membuktikan penerapan efektif dari teori Flow, di mana tantangan aplikasi diselaraskan secara dinamis dengan peningkatan kompetensi pengguna. Dibandingkan dengan platform pembelajaran statis, sistem ini menawarkan nilai tambah berupa interaktivitas yang adaptif, menjadikannya model bisnis digital yang berdaya saing tinggi di sektor pendidikan inklusif.

Temuan akurasi 98,92% dalam riset ini menunjukkan hasil yang sangat kompetitif jika dibandingkan dengan penelitian sebelumnya. Sebagai perbandingan, studi oleh Saleh (2025) yang juga menggunakan SVM dan MediaPipe mencatat akurasi sebesar 97,8%. Peningkatan performa pada penelitian ini didorong oleh penerapan teknik normalisasi koordinat yang dihitung relatif terhadap titik pergelangan tangan (*wrist point*), sehingga memberikan stabilitas prediksi yang lebih optimal. Pencapaian ini sejalan dengan tren pengenalan isyarat *real-time* yang memanfaatkan *ensemble learning* untuk menstabilkan prediksi (Khekare et al., 2025). Tingginya akurasi model yang dicapai juga memperkuat prinsip bahwa ukuran dan kualitas sampel pelatihan sangat menentukan performa algoritma *machine learning* (Kupidura et al., 2024). Lebih lanjut, hal ini menegaskan bahwa penggunaan algoritma adaptif yang ringan sangat relevan untuk diimplementasikan pada sistem pengenalan bahasa isyarat waktu-nyata (*real-time*) di masa depan (Khekare et al., 2025).

4. CONCLUSION

Sistem klasifikasi gestur SIBI berbasis *client-side inference* dengan mekanisme gamifikasi adaptif telah berhasil dikembangkan dan divalidasi. Integrasi model SVM dan MediaPipe menghasilkan akurasi klasifikasi sebesar 98,92%, yang menjamin keandalan sistem dalam proses deteksi gestur pengguna. Penerapan algoritma AGDL secara dinamis mampu menyesuaikan tingkat kesulitan materi berdasarkan performa nyata, sehingga efektif dalam meningkatkan keterlibatan dan motivasi belajar mandiri. Evaluasi usability dengan skor SUS 86,0 mengonfirmasi bahwa sistem memiliki tingkat keberterimaan yang luar biasa dari sisi pengguna. Penelitian ini menawarkan solusi teknologi pendidikan yang efisien secara komputasi, privat, dan skalabel untuk mendukung inklusivitas komunikasi bagi komunitas Tuli.

5. ACKNOWLEDGMENT

Penulis menyampaikan ucapan terima kasih yang sebesar-besarnya kepada Bapak Dedy Irfan selaku pembimbing yang telah memberikan arahan teknis, kritik konstruktif, serta bimbingan yang sangat berharga selama proses penelitian ini. Terima kasih juga ditujukan kepada Departemen Teknik Elektronika, Fakultas Teknik, Universitas Negeri Padang atas dukungan fasilitas laboratorium dan ekosistem riset yang kondusif. Penghargaan setinggi-tingginya diberikan kepada rekan-rekan mahasiswa yang telah bersedia menjadi responden dalam pengujian sistem, serta komunitas Tuli yang menjadi inspirasi utama dalam pengembangan solusi teknologi inklusif ini.

6. AUTHORS' NOTE

Penulis menyatakan bahwa tidak terdapat konflik kepentingan (*conflict of interest*) dalam publikasi artikel ini, baik dari segi finansial maupun hubungan personal dengan pihak manapun. Penulis juga menegaskan bahwa karya ini merupakan hasil penelitian orisinal dan bebas dari unsur plagiarisme. Seluruh data dan literatur yang dirujuk telah dicantumkan secara transparan dalam daftar pustaka.

7. REFERENCES

- Aggarwal, S., & Verma, J. (2022). Comparative analysis of ReactJS and AngularJS in web development. *International Journal of Computer Applications*, 183(45), 34–38. <https://doi.org/10.5120/ijca2022921868>
- Bora, J., Dehingia, S., Boruah, A., Chetia, A. A., & Gogoi, D. (2023). Real-time Assamese Sign Language Recognition using MediaPipe and Deep Learning. *Procedia Computer Science*, 218, 1384–1393. <https://doi.org/10.1016/j.procs.2023.01.117>
- Choi, J., Kim, S., & Park, J. (2020). Efficient client-side deep learning for privacy-preserving web applications. *Web Intelligence*, 18(2), 115–128. <https://doi.org/10.3233/WEB-200435>
- Dichev, C., & Dicheva, D. (2017). Gamifying education: What is known, what is believed and what remains uncertain: A critical review. *International Journal of Educational Technology in Higher Education*, 14, 9. <https://doi.org/10.1186/s41239-017-0042-5>
- Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: An overview. *ArXiv Preprint ArXiv:2008.05756*. <https://arxiv.org/abs/2008.05756>
- Jin, T., Bercea, G.-T., Le, T. D., Chen, T., Su, G., Imai, H., Negishi, Y., Leu, A., O'Brien, K., Kawachiya, K., & Eichenberger, A. E. (2020). *Compiling ONNX Neural Network Models Using MLIR*. <http://arxiv.org/abs/2008.08272>
- Khekare, G., Panigrahi, G. R., Singh, V., Majumder, G., & Shelke, N. (2025). Adaptive ensemble learning for real time sign language recognition. *2025 3rd International Conference on Networks & Advances in Computational Technologies (NetACT)*. <https://doi.org/10.1109/NetACT65906.2025.11188939>
- Krath, J., Schürmann, L., & von Korfflesch, H. F. O. (2021). Revealing the theoretical basis of gamification: A systematic review and analysis of theory in research on gamification, serious games and game-based learning. *Computers in Human Behavior*, 125. <https://doi.org/10.1016/j.chb.2021.106963>
- Kupidura, P., Kępa, A., & Krawczyk, P. (2024). Comparative analysis of the performance of selected machine learning algorithms depending on the size of the training sample. *Reports on Geodesy and Geoinformatics*, 118(1). <https://doi.org/10.2478/rgg-2024-0015>
- Legaki, N.-Z., Xi, N., Hamari, J., Karpouzis, K., & Assimakopoulos, V. (2020). The effect of challenge-based gamification on learning: An experiment in the context of statistics education. *International Journal of Human-Computer Studies*, 144, 102496. <https://doi.org/10.1016/j.ijhcs.2020.102496>
- Liu, H.-I., Galindo, M., Xie, H., Wong, L.-K., Shuai, H.-H., Li, Y.-H., & Cheng, W.-H. (2024). *Lightweight Deep Learning for Resource-Constrained Environments: A Survey*. <http://arxiv.org/abs/2404.07236>

- Lugaresi, C., Tang, J., Nash, H., McClanahan, C., Uboweja, E., Hays, M., Zhang, F., Chang, C.-L., Yong, M. G., Lee, J., Chang, W.-T., Hua, W., Georg, M., Grundmann, M., & Kalakrishnan, R. (2019). MediaPipe: A framework for building perception pipelines. *ArXiv Preprint ArXiv:1906.08172*. <https://arxiv.org/abs/1906.08172>
- Niswati, Z., Mustajib, F. S., & Sujatmiko, A. (2021). Sign language recognition using Support Vector Machine (SVM) and convex hull algorithm. *Journal of Physics: Conference Series*, 1842(1), 012014. <https://doi.org/10.1088/1742-6596/1842/1/012014>
- Nugraheni, A. S., Husain, A. P., & Unayah, H. (2023). OPTIMALISASI PENGGUNAAN BAHASA ISYARAT DENGAN SIBI DAN BISINDO PADA MAHASISWA DIFABEL TUNARUNGU DI PRODI PGMI UIN SUNAN KALIJAGA. *Jurnal Holistika*, 5(1), 28. <https://doi.org/10.24853/holistika.5.1.28-33>
- Ostermann, A., Vollmuth, P., & Ziemsky, V. (2023). Design and Application of the unit-e2 Project Use Case Methodology. *World Electric Vehicle Journal*, 14(1). <https://doi.org/10.3390/wevj14010013>
- Paudyal, P., Banerjee, A., & Gupta, S. (2020). On evaluating the effects of feedback for sign language learning using explainable AI. *Companion Proceedings of the 25th International Conference on Intelligent User Interfaces (IUI '20 Companion)*, 83–84. <https://doi.org/10.1145/3379336.3381469>
- Romão, L. C., Villamizar, H., Oliveira, R., Alonso, S., & Kalinowski, M. (2025). Agile management for machine learning: A systematic mapping study. *ArXiv Preprint ArXiv:2506.20759*. <https://arxiv.org/abs/2506.20759>
- Saleh, A. (2025). A Comparative Analysis of CNN and SVM for Static Sign Language Recognition Using MediaPipe Landmarks. *Journal of Intelligent System and Telecommunication*, 1(2), 225–238. <https://doi.org/10.26740/jistel.v1n2.p225-238>
- Sruthi, C. J., & Sasikala, A. L. (2021). Sign language recognition using SVM and neural network. *2021 7th International Conference on Advanced Computing and Communication Systems (ICACCS)*, 774–778. <https://doi.org/10.1109/ICACCS51430.2021.9441865>
- Wang, Q., Jiang, S., Chen, Z., Cao, X., Li, Y., Li, A., Ma, Y., Cao, T., & Liu, X. (2025). Anatomizing Deep Learning Inference in Web Browsers. *ACM Transactions on Software Engineering and Methodology*, 34(2). <https://doi.org/10.1145/3688843>
- Wibowo, A. S., Purnama, B. E., & Wardati, I. U. (2023). Aplikasi pembelajaran bahasa isyarat SIBI berbasis Android menggunakan metode Linear Congruent Method. *Jurnal Ilmiah SINUS*, 21(1), 1–12. <https://doi.org/10.30646/sinus.v21i1.667>
- Zhang, F., Bazarevsky, V., Vakunov, A., Tkachenka, A., Sung, G., Chang, C.-L., & Grundmann, M. (2020). *MediaPipe Hands: On-device Real-time Hand Tracking*. <http://arxiv.org/abs/2006.10214>