P-ISSN : 2580-4316
E-ISSN : 2654-8054 https://doi.org/10.37817/ikraith-informatika.v11i2

RANCANGAN BANGUN APLIKASI PENERJEMAH BAHASA ISYARAT DENGAN DEEP LEARNING MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN)

Fadly Maulana Adiyasa
[1]Program Studi Teknik Informatika, Universitas Persada Indonesia Y.A.I, Jakarta

E-mail: fadlyadiyasa9@gmail.com

ABSTRAK

Komunikasi merupakan kebutuhan vital, namun penyandang tunarungu sering mengalami hambatan saat berinteraksi dengan masyarakat awam yang minim pemahaman terhadap bahasa isyarat. Penelitian ini bertujuan merancang bangun aplikasi penerjemah Sistem Isyarat Bahasa Indonesia (SIBI) ke dalam teks secara real-time berbasis Android guna mempermudah komunikasi tersebut. Sistem ini dikembangkan memanfaatkan kecerdasan buatan deep learning dengan algoritma Convolutional Neural Network (CNN) berarsitektur MobileNetV2 dan diintegrasikan dengan kerangka kerja MediaPipe HandLandmarker untuk melacak koordinat batas tangan. Proses klasifikasi berjalan secara offline di dalam perangkat menggunakan TensorFlow Lite untuk menerjemahkan 24 huruf alfabet SIBI yang bersifat statis. Berdasarkan pengujian langsung di lingkungan dengan kondisi ideal, sistem berhasil mencapai tingkat confidence rata-rata sebesar 95,19% pada smartphone dan 97,50% pada tablet. Secara keseluruhan, aplikasi telah berhasil beroperasi secara responsif tanpa terjadinya kebocoran memori (force close) dan tangguh dalam menangani gangguan dua tangan. Meskipun demikian, performa ekstraksi fitur sistem masih dapat menurun pada kondisi lingkungan ekstrem, seperti paparan cahaya silau (backlight) dan latar belakang visual yang ramai.

Kata kunci : ***Android, Convolutional Neural Network (CNN), Deep Learning, MediaPipe, Sistem Isyarat Bahasa Indonesia (SIBI).***

ABSTRACT

This Communication is a vital necessity, however, the deaf community often faces barriers when interacting with the general public, who typically have limited understanding of sign language. This research aims to develop an Android-based application that translates the Indonesian Sign Language System (SIBI) into text in real-time to facilitate such communication. The system utilizes deep learning—specifically a Convolutional Neural Network (CNN) with a MobileNetV2 architecture—and integrates the Media Pipe Hand Landmarker framework to track hand landmark coordinates. Classification occurs offline on the device using TensorFlow Lite to translate the 24 static letters of the SIBI alphabet. Testing in ideal environments demonstrated that the system achieved an average confidence level of 95.19% on smartphones and 97.50% on tablets. Overall, the application operates responsively without memory leaks (crashes) and robustly handles two-handed gestures. Nevertheless, feature extraction performance may decline under extreme environmental conditions, such as strong backlighting or cluttered visual backgrounds.

Keyword : ***Android, Convolutional Neural Network (CNN), Deep Learning, MediaPipe, Indonesian Sign Language System (SIBI).***

P-ISSN : 2580-4316
E-ISSN : 2654-8054
https://doi.org/10.37817/ikraith-informatika.v11i2

1. PENDAHULUAN

Komunikasi memainkan peran yang sangat penting bagi manusia sebagai makhluk sosial dalam menjalani aktivitas sehari-hari. Komunikasi bukan sekadar alat interaksi, melainkan sebuah kebutuhan hidup yang memungkinkan individu untuk membangun ikatan, saling memahami, serta bertukar informasi dan emosi dengan orang lain dalam berbagai situasi sosial. Maka dari itu, setiap orang perlu memiliki keterampilan berkomunikasi yang efektif agar bisa menjalani kehidupan sosialnya dengan baik dan bermakna, termasuk bagi mereka yang memiliki keterbatasan fisik maupun sensorik seperti penyandang tunarungu. Pentingnya komunikasi untuk penyandang tunarungu tidak hanya terletak pada aspek sosial, tetapi juga dalam peningkatan kualitas hidup, akses pendidikan, dan keterlibatan penuh dalam masyarakat.

Fungsi komunikasi bagi mereka menjadi sangat vital sebagai sarana utama untuk mengekspresikan keinginan, menyampaikan perasaan, serta mengakses dan menyebarkan informasi yang sangat diperlukan dalam aktivitas seharihari. Namun, seringkali mereka menghadapi tantangan besar, terutama individu yang mengalami kesulitan dalam mendengar dan berbicara, karena keterbatasan tersebut dapat menjadi penghalang yang cukup berarti dalam melakukan komunikasi baik secara lisan maupun nonverbal.

Bahasa isyarat berperan sebagai alat komunikasi yang sangat penting bagi individu dengan disabilitas pendengaran dalam kehidupan sehari-hari untuk menjaga komunikasi yang efektif dengan orang-orang di sekitarnya. Bahasa isyarat berfungsi sebagai alat penghubung komunikasi yang penting bagi penyandang tunarungu dan individu dengan disabilitas pendengaran lainnya, memberi mereka kesempatan untuk menyampaikan gagasan, emosi, serta kebutuhan dengan lebih jelas dan mudah dimengerti oleh orang lain, sehingga menciptakan interaksi yang nyaman dan saling menghormati.

Menurut data yang dipublikasikan oleh Kementerian Sosial Indonesia pada tahun 2023, terungkap bahwa jumlah individu dengan disabilitas tunarungu di Indonesia mencapai sekitar 22,97 juta orang. Angka yang signifikan ini dengan jelas menunjukkan perlunya pengembangan metode komunikasi yang inklusif dan teknologi yang bisa mendukung kehidupan sosial serta akses informasi bagi individu dengan disabilitas ini secara lebih efisien. Untuk mengatasi masalah ini, akan dirancang sebuah aplikasi untuk menerjemahkan bahasa isyarat dengan memanfaatkan machine learning dan bekerja pada platform Android. Upaya pembuatan aplikasi penerjemah bahasa isyarat ini bertujuan untuk menawarkan solusi teknologi yang modern dan mudah diakses melalui smartphone Android, sehingga memudahkan dalam menerjemahkan bahasa isyarat yang biasa digunakan oleh penyandang tunarungu ke dalam teks. Diharapkan aplikasi ini bisa berfungsi sebagai sarana yang mendukung kegiatan sosial serta meningkatkan akses komunikasi di berbagai tempat, mulai dari rumah, sekolah, hingga tempat kerja.

Aplikasi ini direncanakan akan menggunakan kamera smartphone Android untuk merekam gerakan tangan pengguna. Gerakan tangan tersebut akan dianalisis secara langsung menggunakan model deep learning yang dikembangkan dengan algoritma Convolutional Neural Network (CNN) berbasis TensorFlow, sebuah teknologi machine learning untuk pengenalan pola dan klasifikasi gambar.

P-ISSN : 2580-4316
E-ISSN : 2654-8054 https://doi.org/10.37817/ikraith-informatika.v11i2

Model CNN ini akan mengolah data gambar dari gerakan tangan pengguna dan mengubahnya menjadi teks, menciptakan interaksi yang mulus antara orang dengan disabilitas dan lingkungan mereka, sambil memberikan pengalaman komunikasi.

2. LANDASAN TEORI

Ketentuan Umum

Panjang 6.144 citra, dengan pembagian 80% untuk pelatihan dan 20% untuk validasi. Pembagian tersebut menghasilkan 4.913 citra latih dan 1.231 citra validasi. Data uji dipisahkan sejak awal dan tidak digunakan dalam pelatihan maupun validasi. Data uji terdiri atas 1.536 citra, yaitu 64 citra untuk setiap kelas.

Prapemrosesan dilakukan dengan ukuran masukan 224 x 224 piksel sesuai MobileNetV2. Augmentasi pada data latih meliputi rotasi hingga 15 derajat, translasi 10%, *zoom* 15%, perubahan kontras hingga sekitar 40%, konversi acak ke skala abu-abu dengan probabilitas 25%, dan peningkatan paparan dengan faktor 1,0-1,4 pada probabilitas 25%. Data validasi dan data uji tidak diberi augmentasi agar tetap mencerminkan performa pada data yang belum pernah dilihat. Normalisasi menggunakan fungsi *preprocess_input* MobileNetV2.

Tabel 2. Konfigurasi data dan model

Parameter	Nilai
Kelas / masukan	24 huruf / 224 x 224 RGB
Data	4.913 latih; 1.231 validasi; 1.536 uji
Model / keluaran	MobileNetV2 / Softmax 24 kelas

2.1 Arsitektur dan Pelatihan Model

Lapisan klasifikasi standar MobileNetV2 dihapus dengan parameter *include_top=False*. Fitur dari model dasar diteruskan ke *Global Average Pooling 2D*, dua lapisan *Dense* berukuran 512 dan 256 neuron dengan aktivasi ReLU, *Batch Normalization*, serta *Dropout* 0,4 dan 0,3. Lapisan keluaran menggunakan Softmax untuk menghasilkan probabilitas 24 kelas.

Pelatihan dilaksanakan dalam dua fase. Pada fase pertama, seluruh lapisan dasar MobileNetV2 dibekukan dan lapisan klasifikasi dilatih maksimum 15 *epoch* dengan *learning rate* 1e-3. Pada fase kedua, 30 lapisan terakhir dibuka untuk *fine-tuning* maksimum 30 *epoch* dengan *learning rate* 1e-4. *ModelCheckpoint* menyimpan bobot dengan akurasi validasi tertinggi, *EarlyStopping* menghentikan pelatihan jika tidak ada perbaikan, dan *ReduceLROnPlateau* menurunkan laju pembelajaran saat *loss* validasi stagnan.

2.2 Implementasi Aplikasi Android

Aplikasi dibangun dengan Kotlin pada Android Studio. CameraX mengambil *frame* kamera dan menggunakan strategi *keep only latest* agar hanya citra terbaru yang diproses. Pemrosesan dijalankan pada *single background thread* untuk menjaga antarmuka tetap responsif. Ketika aplikasi ditutup, *executor*, interpreter TensorFlow Lite, dan MediaPipe dihentikan untuk mencegah kebocoran memori.

MediaPipe HandLandmarker diatur untuk mendeteksi maksimum dua tangan dengan ambang kepercayaan 0,5. Sistem menghitung *bounding box* setiap tangan dan memilih area terbesar sebagai objek utama. Koordinat normalisasi dikonversi ke piksel, kemudian ditambah *padding* 40 piksel yang dibatasi agar tidak melewati tepi citra. Apabila deteksi tangan gagal, aplikasi menggunakan citra penuh sebagai mekanisme *fallback* agar proses tetap berjalan.

Citra hasil pemotongan diubah menjadi 224 x 224 piksel dan dimasukkan

P-ISSN : 2580-4316
E-ISSN : 2654-8054
https://doi.org/10.37817/ikraith-informatika.v11i2

ke *ByteBuffer* RGB. Nilai piksel dinormalisasi dari rentang 0-255 menjadi -1 sampai 1 menggunakan rumus (piksel - 127,5) / 127,5. Interpreter TensorFlow Lite menghasilkan probabilitas setiap huruf, kemudian aplikasi menampilkan label dengan probabilitas tertinggi dan nilai *confidence*.



Gambar 2. Tampilan hasil deteksi huruf SIBI pada aplikasi

2.3 Skenario Pengujian

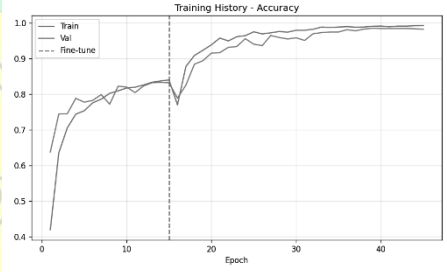
Pengujian dibagi menjadi tiga kelompok. Pertama, evaluasi model menggunakan akurasi, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Kedua, pengujian *black-box* memeriksa 12 skenario, termasuk peluncuran aplikasi, *splash screen*, izin kamera, deteksi tangan, mekanisme *fallback*, perubahan warna prediksi, dan pelepasan memori. Ketiga, pengujian kondisi nyata menilai hasil pada lingkungan ideal dan kondisi yang lebih menantang.

Pengujian kondisi ideal dilakukan pada jarak sekitar 50 cm, pencahayaan terang dan merata, serta latar belakang polos. Pengujian lanjutan mencakup jarak sekitar 30 cm dan 100 cm, kondisi *low light* dan *backlight*, latar belakang ramai, tangan terpotong oleh bingkai kamera, serta dua tangan yang masuk bersamaan. Perangkat yang digunakan adalah Xiaomi 12T dengan kamera 20 MP dan Xiaomi Pad 7 dengan kamera 8 MP.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan dan Pengujian Model

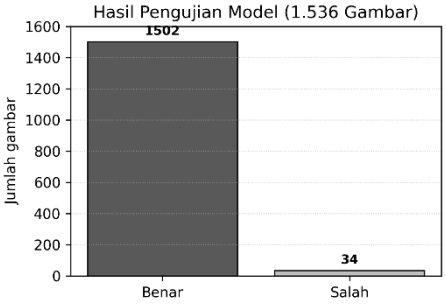
Pelatihan berlangsung selama 45 *epoch*, yaitu 15 *epoch* pada fase pertama dan 30 *epoch* pada fase *fine-tuning*. Pada fase pertama, akurasi latih meningkat dari 41,98% menjadi 83,98%, sedangkan akurasi validasi bergerak dari 63,77% ke kisaran 83%. Pembukaan 30 lapisan terakhir pada awal fase kedua menimbulkan penurunan sementara akibat penyesuaian gradien. Setelah model beradaptasi, akurasi validasi mencapai nilai tertinggi 98,46% pada *epoch* ke-39 dengan akurasi latih 99,03%. Pola peningkatan ditunjukkan pada Gambar 3.



Gambar 3. Perubahan akurasi pelatihan dan validasi

Pada 1.536 citra uji terpisah, model mengklasifikasikan 1.502 citra dengan benar dan 34 citra secara keliru. Hasil tersebut menghasilkan akurasi 97,79% dengan rata-rata *confidence* 98,31%. Kedekatan antara akurasi dan nilai keyakinan menunjukkan bahwa model umumnya yakin ketika menghasilkan prediksi, bukan sekadar menebak secara acak. Perbandingan jumlah prediksi benar dan salah disajikan pada Gambar 4.

P-ISSN : 2580-4316
E-ISSN : 2654-8054 https://doi.org/10.37817/ikraith-informatika.v11i2



Gambar 4. Hasil pengujian model pada 1.536 citra

Tabel 3. Ringkasan kinerja model

Metrik	Hasil
Akurasi / confidence	97,79% / 98,31%
Prediksi benar / salah	1.502 / 34
Macro P / R / F1	0,979 / 0,978 / 0,978
Kelas skor sempurna	C, D, O, Q, Y

Lima kelas C, D, O, Q, dan Y memperoleh *precision*, *recall*, dan *F1-score* sebesar 1,000. Huruf E memiliki *precision* terendah, yaitu 0,901, walaupun *recall*-nya 1,000. Hal ini terjadi karena beberapa citra dari kelas lain salah diprediksi sebagai E. Huruf S memiliki *recall* terendah 0,922, diikuti N dan F sebesar 0,938 serta X sebesar 0,953. Kesalahan tunggal terbanyak adalah empat citra S yang diprediksi sebagai E. Pertukaran dua arah juga terlihat pada M-N dan T-X. Pola ini menegaskan bahwa kemiripan konfigurasi jari menjadi sumber utama kesalahan, bukan distribusi data karena setiap kelas memiliki jumlah data uji yang sama.

3.2 Hasil Pengujian Fungsional

Seluruh 12 skenario *black-box* berstatus valid pada smartphone dan tablet. Aplikasi dapat dibuka tanpa *force close*, menampilkan *splash screen*, meminta dan menangani izin kamera, memuat MediaPipe, mendeteksi tangan, menjalankan *fallback*, mengubah warna hasil sesuai nilai *confidence*, serta menutup aplikasi dengan aman. Tingkat keberhasilan fungsional sebesar 100% menunjukkan bahwa alur antarmuka, pemrosesan kamera, dan manajemen memori berjalan konsisten pada dua ukuran layar dan konfigurasi perangkat yang berbeda.

Penggunaan satu *background executor* dan strategi hanya memproses *frame* terbaru membantu mempertahankan responsivitas. Mekanisme sinkronisasi saat aplikasi ditutup juga berhasil mencegah akses bersamaan terhadap interpreter yang telah dilepas. Hasil ini sesuai dengan tujuan pengembangan aplikasi Android yang aman dan efisien pada perangkat pengguna (Mayrhofer et al., 2021; Pratama et al., 2023).

3.3 Pengujian Kondisi Nyata

Tabel 4. Ringkasan pengujian kondisi nyata

Skenario	Temuan utama
Ideal	Semua 24 huruf benar; confidence rata-rata 95,19% pada smartphone dan 97,50% pada tablet.
Variasi jarak	Pada 30 cm, S kadang terbaca E; pada 100 cm label benar tetapi confidence tablet lebih berfluktuasi.
Variasi cahaya	Low light masih stabil; backlight membuat S terbaca E dan X tidak stabil pada tablet.
Latar / posisi	Latar ramai memicu X-Q; tangan terpotong menyebabkan X gagal dan Y cenderung terbaca L.
Dua tangan	Tangan depan selalu dipilih; lima pasangan pengujian seluruhnya benar.

Pada kondisi ideal, seluruh 24 huruf diprediksi dengan benar pada kedua perangkat. Rata-rata *confidence* pada tablet mencapai 97,50%, sedikit lebih tinggi dibandingkan smartphone sebesar

P-ISSN : 2580-4316
E-ISSN : 2654-8054
https://doi.org/10.37817/ikraith-informatika.v11i2

95,19%. Walaupun beberapa huruf seperti N, S, U, dan V mengalami fluktuasi, label yang ditampilkan tetap konsisten. Temuan ini menunjukkan bahwa model memiliki generalisasi yang baik ketika pencahayaan, jarak, dan latar belakang mendukung.

Variasi jarak memperlihatkan bahwa objek yang lebih dekat tidak selalu menghasilkan prediksi lebih baik. Pada jarak sekitar 30 cm, huruf S pada smartphone sering berubah menjadi E dengan *confidence* 45-86%. Pemotongan yang terlalu ketat diduga menghilangkan bagian jari yang membedakan kedua gestur. Pada jarak sekitar 100 cm, S dan X tetap dikenali, walaupun kamera tablet dengan resolusi lebih rendah menunjukkan fluktuasi *confidence* karena detail halus jari berkurang. Kondisi *low light* masih dapat ditangani selama kontur tangan dapat diekstraksi. Sebaliknya, *backlight* menjadi gangguan terbesar. Huruf S selalu terbaca sebagai E pada kedua perangkat, sedangkan huruf X pada tablet berubah antara F, T, dan X dengan keyakinan rendah. Cahaya dari belakang membentuk siluet gelap sehingga tekstur dan kedalaman jari yang diperlukan untuk membedakan kelas menjadi hilang.

Latar belakang ramai menurunkan stabilitas ekstraksi fitur. Huruf X pada smartphone dominan terbaca sebagai Q, sementara E, N, O, dan S masih dapat diprediksi dengan penurunan keyakinan. Ketika bagian tangan terpotong oleh bingkai kamera, huruf X gagal dikenali pada kedua perangkat. Pada gestur Y, hilangnya rentangan ibu jari membuat tablet lebih sering memprediksi L. Hasil tersebut menunjukkan bahwa sistem memerlukan bentuk tangan yang relatif utuh agar fitur spasial dapat diekstraksi.

Pada skenario dua tangan, sistem selalu memprioritaskan tangan yang berada di depan berdasarkan luas *bounding box*. Lima pasangan gestur, termasuk pasangan pengecoh S di depan dan E di belakang, seluruhnya diprediksi dengan benar. Keberhasilan ini membuktikan bahwa pemilihan area terbesar efektif mengurangi gangguan dari tangan sekunder.

3.4 Pembahasan

Akurasi data uji sebesar 97,79% berada pada tingkat yang kompetitif dibandingkan penelitian terdahulu. Nilainya lebih rendah daripada akurasi pelatihan sekitar 99% yang dilaporkan Nur Budiman et al. (2023), Agata et al. (2024), dan Al-Hafizh dan Alamsyah (2024), tetapi pengujian penelitian ini menggunakan data terpisah dan dilengkapi evaluasi langsung pada perangkat. Perbedaan antara hasil laboratorium dan kondisi nyata menegaskan bahwa akurasi model saja belum cukup untuk menggambarkan kualitas aplikasi penerjemah bahasa isyarat.

Integrasi MediaPipe dengan CNN memberikan dua keuntungan. Pertama, pemotongan tangan mengurangi gangguan latar belakang. Kedua, pemilihan *bounding box* terbesar memungkinkan sistem tetap fokus ketika dua tangan muncul. Namun, ketergantungan pada hasil lokalisasi juga menimbulkan kelemahan ketika tangan terlalu dekat atau terpotong. Temuan ini konsisten dengan karakteristik sistem visi komputer yang sangat dipengaruhi kualitas informasi visual (Fachrisyam et al., 2025) dan menunjukkan pentingnya variasi data pada kondisi ekstrem.

Pendekatan TensorFlow Lite memungkinkan proses berjalan *offline* dan mengurangi latensi komunikasi dengan server. MobileNetV2 juga sesuai untuk perangkat bergerak karena efisiensi parameternya (Gulzar, 2023). Dengan demikian, kontribusi utama penelitian bukan hanya pada akurasi, tetapi pada penyediaan prototipe lengkap yang menghubungkan pelatihan model, deteksi

P-ISSN : 2580-4316
E-ISSN : 2654-8054 https://doi.org/10.37817/ikraith-informatika.v11i2

tangan, inferensi *on-device*, antarmuka kamera, dan pengujian lintas perangkat.

4. METODOLOGI

Metode penelitian yang digunakan adalah prototipe yang terdiri dari beberapa tahapan yaitu:

a) Studi literatur Mengumpulkan referensi mendalam terkait pengenalan citra, deep learning, algoritma Convolutional Neural Network (CNN), serta implementasinya menggunakan framework seperti TensorFlow dan integrasi dengan Android Studio.
b) Pengumpulan dan Persiapan dataset Pengumpulan dataset meliputi pengumpulan gambar pose dalam bahasa isyarat berdasarkan pedoman SIBI dan persiapan dataset meliputi pengategorian dan pelabelan.
c) Perancangan sistem Merancang arsitektur aplikasi dan arsitektur model Convolutional Neural Network (CNN).
d) Implementasi Melakukan penulisan program ke dalam bahasa pemrograman.

5. HASIL DAN PEMBAHASAN

Aplikasi berhasil dikembangkan sebagai penerjemah bahasa isyarat SIBI berbasis Android. Sistem bekerja dengan menangkap gambar tangan melalui kamera, melakukan deteksi landmark menggunakan MediaPipe, kemudian melakukan klasifikasi menggunakan model CNN. Penggunaan CNN memungkinkan sistem mengenali pola visual dari bentuk tangan dan menghasilkan prediksi huruf. Berdasarkan pengujian, sistem mampu mengenali 24 huruf alfabet SIBI statis dengan tingkat confidence yang tinggi. Hasil pengujian menunjukkan rata-rata confidence sebesar 95,19% pada smartphone dan 97,50% pada tablet. Sistem juga mampu berjalan secara responsif tanpa mengalami kebocoran memori atau force close. Namun, terdapat beberapa keterbatasan. Performa sistem dapat menurun ketika kondisi pencahayaan kurang baik, terdapat cahaya belakang yang kuat, atau latar belakang memiliki banyak objek yang mengganggu proses ekstraksi fitur.

Gambar yang disarankan pada bagian pembahasan:

a) Diagram alur sistem (kamera → MediaPipe → CNN → teks).
b) Arsitektur model CNN/MobileNetV2.
c) Tampilan antarmuka aplikasi Android.
d) Contoh proses deteksi tangan dan hasil prediksi huruf.
e) Grafik hasil pengujian confidence model.

6. KESIMPULAN

Berdasarkan keseluruhan tahapan penelitian yang meliputi perancangan arsitektur, pelatihan model machine learning, penerapan dalam platform Android, serta pengujian fungsionalitas dan uji di lingkungan nyata pada aplikasi penerjemah bahasa isyarat SIBI, ada beberapa hal yang dapat disimpulkan. Model Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2 dan modul MediaPipe HandLandmarker telah berhasil diintegrasikan ke dalam ekosistem Android menggunakan bahasa pemrograman Kotlin. Sistem

7. UCAPAN TERIMA KASIH

Dengan memanjatkan puji dan syukur kehadirat Allah SWT, sehingga penulis dapat menyelesaikan penelitian ini dengan baik. Dalam pengerjaan tugas akhir ini, penulis menyadari bahwa penulis

P-ISSN : 2580-4316
E-ISSN : 2654-8054
https://doi.org/10.37817/ikraith-informatika.v11i2

mendapatkan banyak bantuan, arahan, dan dukungan dari berbagai pihak sejak awal hingga akhir, oleh karna itu penulis ingin menyampaikan ucapan terima kasih kepada:

a) Rektor Prof, Ir, Sri Astuti Indriyati, MS., Ph.D, selaku Rektor Universitas Persada Indonesia Y.A.I.
b) Dekan Dr. Ir. Fitri Suryani, MT, selaku Dekan Fakultas Teknik UPI Y.A.I.
c) Kepala Prodi M. Anno Suwarno, S.Kom., M.Kom, selaku Ketua Program Studi Teknik Informatika/Sistem Informasi FT-UPI Y.A.I.
d) Ibu Angries, S.Kom., MTI., selaku dosen pembimbing yang telah meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan serta arahan kepada penulis dalam menyelesaikan Tugas Akhir ini
e) Segenap Dosen dan Staf Karyawan di lingkungan Fakultas Teknik Universitas Persada Indonesia Y.A.I yang telah membantu kelancaran proses perkuliahan maupun administrasi selama penulis menempuh pendidikan.
f) Orang tua yang selalu memberikan doa tiada henti, serta dukungan baik secara moral maupun material sehingga penulis senantiasa semangat dan pantang menyerah dalam menyelesaikan Tugas Akhir ini.
g) Teman-teman seperjuangan yang telah memberikan bantuan, dukungan, serta bersedia menjadi tempat bertukar pikiran selama proses pengerjaan Tugas Akhir ini.
h) Terima kasih juga kepada seluruh pihak yang telah memberikan semangat dan dukungan dalam penyusunan Tugas Akhir ini, baik secara langsung maupun tidak langsung, yang tidak dapat penulis sebutkan satu per satu.

DAFTAR PUSTAKA

Agata, A. W., Saputra, W. S. J., & Putra, C. A. (2024). Pengenalan Bahasa Isyarat Indonesia (BISINDO) menggunakan algoritma Scale Invariant Feature Transform (SIFT) dan Convolutional Neural Network (CNN). *JATI (Jurnal Mahasiswa Teknik Informatika), 8*(1), 1054-1061.

Alfiansyah, N. S., & Litanianda, Y. (2024). Identifikasi Lumpy Skin Disease menggunakan TensorFlow dengan metode Convolutional Neuron Network. *JATI (Jurnal Mahasiswa Teknik Informatika), 8*(4), 7330-7336.

Al-Hafizh, F., & Alamsyah, A. (2024). Penerapan model Deep-CNN untuk meningkatan akurasi klasifikasi bahasa isyarat alfabet menggunakan algoritma Convolutional Neural Network. *Indonesian Journal of Mathematics and Natural Sciences, 47*(1), 1-11.

Azizah, E. N., Resmi, M. G., & Alam, S. (2023). Penerapan metode Design Thinking pada perancangan user interface aplikasi mobile pengenalan Bahasa Isyarat Indonesia (BISINDO). *Jurnal Mnemonic, 6*(1), 71-76.

Fachrisyam, M., Indra, D., & Hasnawi, M. (2025). Implementasi metode YOLO dalam mendeteksi jenis sampah berbasis computer vision. *LINIER: Literatur Informatika dan Komputer, 2*(1), 68-76.

Fatmawati, R., Asmara, R., Prayogi, Y. R., & Hakkun, R. Y. (2022). Aplikasi pembelajaran Sistem Isyarat Bahasa Indonesia (SIBI) berbasis voice menggunakan OpenSIBI. *Technomedia Journal, 7*(1), 22-39.

Gafar, A. A., & Sari, J. Y. (2018). Sistem pengenalan Bahasa Isyarat Indonesia dengan menggunakan metode Fuzzy K-Nearest Neighbor. *Jurnal ULTIMATICS, 9*(2), 122-128.

Gulzar, Y. (2023). Fruit image classification model based on MobileNetV2 with deep transfer learning technique. *Sustainability, 15*(3), 1906.

Halder, A., & Tayade, A. (2021). Real-time vernacular sign language recognition using MediaPipe and machine learning. *International Journal of Research Publication and Reviews, 2*.

Kufel, J., Bargiel-Laczek, K., Kocot, S., Kozlik, M., Bartnikowska, W., Janik, M., Czogalik, L., Dudek, P., Magiera, M., & Lis, A. (2023). What is machine learning, artificial neural networks and deep learning? Examples of practical applications in medicine. *Diagnostics, 13*(15), 2582.

Mayrhofer, R., Vander Stoep, J., Brubaker, C., & Kralevich, N. (2021). The Android platform security model. *ACM Transactions on Privacy and Security, 24*(3), 1-35.

Nur Budiman, S., Lestanti, S., & Yuana, H. (2023). SIBI (Sistem Bahasa Isyarat Indonesia) berbasis machine learning dan computer vision untuk membantu komunikasi tuna rungu dan tuna wicara. *Jurnal Teknologi dan Manajemen Informatika*.

Pongtambing, Y. S., Appa, F. E., Siddik, A. M. A., Sampetoding, E. A. M., Admawati, H., Purba, A. A., Sau, A., & Manapa, E. S. (2023). Peluang dan tantangan kecerdasan buatan bagi generasi muda. *Bakti Sekawan: Jurnal Pengabdian Masyarakat, 3*(1), 23-28.

Pratama, S. B., Suharto, M. E. F., & Saputro, W. E. (2023). Aplikasi Covid19 Monitoring berbasis Android menggunakan Android Studio dengan bahasa pemrograman Kotlin. *Sains Data Jurnal Studi Matematika dan Teknologi, 1*(1), 9-20.

Purwono, P., Ma'arif, A., Rahmaniar, W., Fathurrahman, H. I. K., Frisky, A. Z. K., & ul Haq, Q. M. (2022). Understanding of convolutional neural network (CNN): A review. *International Journal of Robotics and Control Systems, 2*(4), 739-748.

Ramadhani, F., Satria, A., & Salamah, S. (2023). Implementasi algoritma Convolutional Neural Network dalam mengidentifikasi dini penyakit pada mata katarak. *Sudo Jurnal Teknik Informatika, 2*(4), 167-175.

Sharifani, K., & Amini, M. (2023). Machine learning and deep learning: A review of methods and applications. *World Information Technology and Engineering Journal, 10*(07), 3897-3904.

Therry, R. W. L., Junaidi, A., & Sihananto, A. N. (2024). Program penerjemah Bahasa Isyarat Indonesia (BISINDO) secara real time menggunakan Convolutional Neural Network dan MediaPipe. *JATI (Jurnal Mahasiswa Teknik Informatika), 8*(6), 11642-11649.