

Sistem Klasifikasi Pola Citra dalam Deteksi Gestur Tangan Pelanggan Menggunakan Metode YOLOv8

Allvintantyo Fristya Gita Nanda¹

¹Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: *¹allvinnanda@gmail.com

Abstrak – Penelitian ini bertujuan mengembangkan sistem deteksi dan klasifikasi gestur tangan pelanggan berbasis citra menggunakan algoritma YOLOv8 sebagai solusi otomatisasi dalam mendukung interaksi layanan tanpa sentuhan. Topik ini dipilih karena kebutuhan identifikasi gestur secara otomatis semakin penting, terutama untuk meningkatkan efisiensi komunikasi antara pelanggan dan pelayan, sekaligus mengurangi sebuah masalah dikala tempat makan sedang ramai dengan kebisingan suara yang mengganggu interaksi pelanggan dan pelayan. Metode penelitian menggunakan pendekatan waterfall, yang terdiri atas tahapan pengumpulan data, pra-proses citra, pelabelan, pemodelan, dan evaluasi. Dataset yang digunakan berjumlah 3.000 citra dengan tiga kelas gestur utama, yaitu konfirmasi, memesan, dan selesai. Proses pelabelan dilakukan melalui Roboflow agar format anotasi selaras dengan kebutuhan deteksi objek. Model YOLOv8 dilatih dan dievaluasi menggunakan metrik akurasi, precision, recall, serta nilai mean Average Precision. Hasil penelitian menunjukkan bahwa sistem mampu mengenali gestur tangan secara akurat dengan nilai akurasi rata-rata sebesar 92,33% dan capaian nilai mAP50 sebesar 0,855. Sistem juga mampu beroperasi secara real-time melalui antarmuka Streamlit dengan tingkat pemrosesan stabil. Hasil penelitian ini membuktikan bahwa pendekatan deteksi objek berbasis citra dapat mendukung identifikasi gestur pelanggan secara cepat, presisi, dan efisien, sehingga berpotensi diterapkan pada sistem pelayanan berbasis komputer visi.

Kata Kunci — Computer Vision, Deteksi Gestur, Real-time, YOLOv8, Pengolahan Citra.

1. PENDAHULUAN


Sistem pelayanan di restoran atau ruang tunggu umumnya masih mengandalkan komunikasi verbal dan isyarat manual yang membutuhkan kehadiran manusia untuk menilai informasi visual. Kondisi tersebut membuka potensi terjadinya kesalahan interpretasi, keterlambatan pelayanan, serta ketidakkonsistenan penilaian visual, terutama ketika jumlah pelanggan meningkat dan suara pada lingkungan terlalu berisik. Deteksi tangan berbasis metode YOLO dan CNN mampu mengidentifikasi area gestur secara otomatis pada video bahasa isyarat, sehingga mengoptimalkan proses interpretasi visual [1]. Penggunaan teknologi YOLO pada sistem pendeteksian gerak tubuh secara real time menghasilkan respons deteksi yang stabil pada aliran video [2]. Namun, pengenalan bentuk gestur membutuhkan pemahaman pola visual yang akurat untuk membedakan posisi tangan beragam bentuk dengan latar belakang berbeda dan keberhasilan deteksi gestur sangat dipengaruhi oleh struktur data pelatihan yang representatif [3].

Dataset gestur berskala besar menunjukkan bahwa kapasitas data menjadi bagian penting dalam pengembangan sistem berbasis pembelajaran mendalam. Dataset HaGRID merupakan dataset yang dirancang khusus untuk mengakomodasi beragam bentuk gestur tangan, sehingga dapat meningkatkan kemampuan model dalam proses generalisasi [4]. Selain itu, dataset tersebut telah dikembangkan menjadi HaGRIDv2, yang berisi citra gestur statis dan dinamis dalam jumlah besar, memberikan ruang lebih luas bagi model untuk mempelajari variasi gestur yang kompleks [5]. Kemajuan teknologi telah membuka potensi yang sangat besar dalam bidang Computer Vision, seperti contoh implementasi YOLOv8 yang mulai diterapkan pada beberapa bidang deteksi objek visual. seperti pengklasifikasian kualitas pisang susu, deteksi bahasa isyarat, deteksi gestur tangan, dan masih banyak hal lain [6].

Berdasarkan situasi tersebut, solusi pada situasi tersebut yaitu mengembangkan sistem klasifikasi pola citra untuk pendeteksian gestur tangan pelanggan menggunakan metode YOLOv8 sebagai solusi utama. YOLOv8 dipilih karena kemampuannya melakukan deteksi objek dalam satu tahapan pemrosesan dengan tingkat kecepatan tinggi serta akurasi yang kompetitif, sehingga memungkinkan sistem bekerja dalam kondisi layanan langsung. Sistem yang dirancang dalam penelitian ini diarahkan untuk mengenali tiga kategori gestur komunikasi pelanggan, yaitu isyarat memanggil (gestur tangan telapak terbuka), tanda konfirmasi pesanan selesai (gestur tangan oke), dan penanda sudah selesai dan akan melakukan pembayaran (gestur tangan mengepal). Dengan memanfaatkan pendekatan pembelajaran mendalam dan dataset beranotasi secara sistematis, penelitian ini diharapkan mampu menghasilkan model klasifikasi citra yang akurat dan efisien, sehingga dapat mendukung pengembangan interaksi layanan pelanggan berbasis visi komputer.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan *Waterfall* sebagai model pengembangan sistem. Pemilihan metode ini didasarkan pada karakteristik proses penelitian yang berjalan secara terstruktur dan berurutan, dimana setiap tahapan harus diselesaikan sebelum melanjutkan ke tahap berikutnya. Alur penelitian telah tercantum pada Gambar 1 berikut:



Gambar 1. Diagram *Waterfall*

2.1 Pengumpulan data

Pada penelitian ini data yang digunakan berjumlah 3.000 citra, dengan pembagian kelas yang seimbang antara tiga kategori gestur, yakni memanggil, konfirmasi pesanan selesai, dan selesai (pembayaran) masing-masing sebanyak 1.000 citra. Dataset diperoleh dari platform *Kaggle* yang menyediakan citra beranotasi dasar dan variasi lingkungan visual yang cukup luas, sehingga dapat mendukung proses pelatihan model secara representatif. Pemilihan dataset dari sumber tersebut juga dipertimbangkan karena kualitas citra yang baik dan struktur data yang sesuai dengan kebutuhan penelitian.



Gambar 2. Dataset pesanan selesai

2.2 *Preprocessing* Data

Pada tahap ini seluruh citra dipersiapkan melalui beberapa langkah penyesuaian, seperti *resizing*, penyeragaman format file, serta pengorganisasian direktori agar sesuai standar input model *YOLOv8*. Dataset cita

disesuaikan *resize* nya menjadi 640 piksel dan semua dataset diubaha menjadi format JPG. Tahap ini bertujuan memastikan bahwa setiap citra memenuhi standar dimensi dan resolusi agar proses pelatihan berjalan optimal.

2.3 Pelabelan Data


Pada penelitian ini proses anotasi/pelabelan dilakukan menggunakan platform *Roboflow*, yang dipilih karena menyediakan sistem pelabelan yang efisien, akurat, serta mampu mengekspor anotasi langsung ke format *YOLO*. Seluruh citra diberi tanda berdasarkan kategori gestur yang diamati, dan setiap objek tangan ditandai menggunakan anotasi *bounding box*. Tahap ini memiliki pengaruh penting terhadap kualitas model karena kesalahan anotasi dapat menurunkan performa deteksi saat model diuji.

2.4 Proses Pelabelan Data (Labeling)

Setelah seluruh data citra terkumpul, penelitian berlanjut ke tahap pelabelan data (data labeling). Proses ini melibatkan pembuatan anotasi berupa bounding box (kotak pembatas) yang secara presisi melingkupi area objek target yaitu buah apel, pisang, anggur, jambu dan semangkaapada setiap gambar dalam dataset. Penandaan ini bertujuan vital untuk melatih model agar mampu mengenali karakteristik fitur visual serta lokasi spasial dari masing-masing kelas objek yang terdapat di dalam citra, sehingga model dapat membedakan antar jenis buah dengan akurat saat proses pelatihan berlangsung.

2.5 Modelling

Pemodelan (*modelling*) menggunakan algoritma *YOLOv8*. Model dilatih menggunakan teknik *transfer learning* dengan bobot awal (*pretrained weight*) yang telah terlatih pada dataset umum, kemudian dilakukan pelatihan lanjutan menggunakan dataset penelitian ini. Selama proses pelatihan, konfigurasi *hyperparameter* ditentukan melalui serangkaian percobaan, termasuk penentuan ukuran gambar, jumlah *epoch*, serta variasi *batch size*. Konfigurasi *hyperparameter* dilakukan untuk sebagai uji coba untuk mencari dan menentukan hasil akurasi yang sesuai dengan harapan. Selain itu, algoritma *YOLOv8* dipilih karena mampu melakukan deteksi dan klasifikasi objek secara langsung dalam satu langkah inferensi, serta menunjukkan performa unggul dalam pengenalan pola citra yang kompleks.



Gambar 3. Arsitektur YOLOv8 [7]

(Sumber gambar : <https://jurnal.polsri.ac.id/index.php/jupiter/article/view/8633/3151>)

2.6 Evaluasi

Model diuji menggunakan data validasi untuk mengukur performa dan ketepatan hasil klasifikasi gestur tangan. Evaluasi dilakukan menggunakan metrik akurasi deteksi serta nilai *precision*, *recall*, *F-1 score* dan *mean Average Precision (mAP)*. Selain itu, perhitungan evaluasi didasarkan menggunakan *Confusion Matrix* seperti tabel dibawah ini :

Tabel 1. *Confusion Matrix*

Class	Class Positive	Class Negative
Positive	TP (True Positive)	TN (True Negative)
Negative	FP (False Positive)	FN (False Negative)

Rumus dari *precision*, *recall*, dan *mean Average Precision (mAP)* dapat dilihat dibawah ini:

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots(1)$$

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots(2)$$


$$F1-Score = 2 \times \frac{precision \times recall}{precision+recall} \dots\dots\dots(3)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \dots\dots\dots(4)$$

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Model (*Training Results*)

Proses pelatihan model YOLOv8 dilakukan menggunakan dataset sebanyak 3000 citra dan telah di *praprocessing*. Hasil dari pelatihan dapat diamati melalui grafik penurunan nilai *Loss* dan peningkatan nilai *mAP* (*mean Average Precision*) pada gambar dibawah ini:



Gambar 4. Grafik *Loss/mAP* dari hasil *training*

Berdasarkan Gambar 4 telah dilakukan *training* sampai *epoch* ke-100, dan hasil Grafik pelatihan memperlihatkan bahwa nilai *loss* pada tahap pelatihan (*train loss*) mengalami penurunan yang stabil sepanjang proses *epoch*. Penurunan tersebut terlihat pada tiga komponen utama, yaitu *train/box_loss*, *train/cls_loss*, dan *train/dfl_loss*, yang menunjukkan bahwa kemampuan model dalam mendeteksi posisi objek, mengklasifikasikan kelas, serta memahami distribusi fitur semakin baik seiring bertambahnya iterasi. Sementara itu, pada data validasi terlihat bahwa nilai *val_loss* sempat menurun pada fase awal pelatihan, kemudian cenderung meningkat kembali menjelang akhir pelatihan. Kondisi ini mengindikasikan adanya kecenderungan *overfitting*, di mana model mulai menyesuaikan diri terlalu kuat pada data pelatihan sehingga performanya pada data baru tidak meningkat secara sebanding. Meski demikian, pola kenaikan tersebut masih tergolong wajar dalam pengembangan model deteksi objek, terutama ketika dataset memiliki variasi citra yang tinggi.

Pada bagian metrik evaluasi, grafik menunjukkan peningkatan performa yang cukup signifikan. Nilai *precision* dan *recall* bergerak naik menuju kisaran 0.80, menandakan bahwa model mampu mengidentifikasi objek gestur tangan secara konsisten tanpa banyak kesalahan prediksi positif maupun kehilangan deteksi objek. Hal ini sejalan dengan nilai *mAP50* yang mencapai kisaran sekitar 0.85, menunjukkan kemampuan model dalam melakukan deteksi objek dengan tingkat ketepatan lokasi tinggi pada ambang *IoU* 0.50. Sementara itu, nilai *mAP50–95* berada pada kisaran yang lebih rendah, yang merupakan kondisi umum karena standar pengukuran area perpotongan objek menjadi lebih ketat.

3.2 Matriks Evaluasi

Setelah melakukan pelatihan, hasil dari pelatihan akan di evaluasi dalam bentuk *confusion matrix* yang dapat dilihat pada gambar di bawah ini:



Gambar 5. *Confusion matrix normalized*

Hasil evaluasi performa model menunjukkan bahwa sistem klasifikasi berbasis *YOLOv8* mampu mengenali gestur tangan dengan tingkat ketepatan yang tinggi untuk tiga kelas utama. Nilai akurasi pada diagonal *confusion matrix* memperlihatkan bahwa kelas *konfirmasi* berhasil diprediksi dengan benar sebesar 0,94, disusul kelas *memesan* dengan nilai 0,93, serta kelas *selesai* dengan nilai 0,90. Ketiga nilai tersebut mencerminkan kemampuan model dalam mengidentifikasi pola visual yang mewakili setiap gestur secara kuat, dan menunjukkan bahwa fitur pembeda yang dimiliki citra pada ketiga kelas dapat dipelajari dengan baik oleh model selama pelatihan. Hal ini sekaligus menggambarkan bahwa metode anotasi dan distribusi data yang digunakan mampu memberikan kontribusi signifikan terhadap keberhasilan prediksi.

Sebaliknya, kelas *background* memiliki nilai prediksi paling rendah dibanding kelas lainnya. Hal ini wajar terjadi karena kelas tersebut tidak mengandung gestur tertentu dan lebih berfungsi sebagai penanda ruang visual kosong pada dataset. Sifat kategori yang tidak spesifik membuat model lebih sulit membedakan antara informasi relevan dan elemen citra yang tidak berhubungan secara langsung dengan objek tangan. Meski begitu, performa keseluruhan model masih berada dalam kategori sangat memuaskan, dengan akurasi rata-rata mencapai 92,33%. Nilai tersebut menunjukkan bahwa model telah memenuhi kriteria keberhasilan yang dibutuhkan untuk diterapkan pada kasus pengenalan gestur pelanggan secara otomatis.


Tabel 2. *Performance Modelling*

Class	Instances	Box Precision	Box Recall	F1-Score	mAP50
All	2103	0.92	0.92	0.82	0.855
Konfirmasi	722	0.94	0.94	0.88	0.884
Memesan	698	0.93	0.93	0.81	0.865
Selesai	683	0.90	0.90	0.76	0.816

Tabel 2 menunjukkan bahwa model *YOLOv8* memiliki performa yang sangat baik dalam mengenali tiga kelas gestur tangan pelanggan. Kelas *konfirmasi* memperoleh nilai deteksi tertinggi dengan *precision* dan *recall* sebesar 0,94, yang menunjukkan bahwa model mampu mengidentifikasi gestur tersebut secara akurat dan stabil. Kelas *memesan* juga memberikan hasil yang sebanding dengan nilai *precision* dan *recall* sebesar 0,93, sedangkan kelas *selesai* memiliki skor sedikit lebih rendah yaitu 0,90, yang dapat dipengaruhi oleh variasi bentuk tangan atau perbedaan sudut pengambilan gambar. Nilai *F1 Score* pada seluruh kelas berada antara 0,76 hingga 0,88, yang mengindikasikan keseimbangan antara tingkat ketepatan prediksi dan kemampuan menangkap objek hand gesture pada citra uji. Selain itu, nilai *mAP50* keseluruhan mencapai 0,855, menandakan bahwa sistem mampu melakukan deteksi pada titik potong objek dengan tingkat ketepatan tinggi. Secara umum, tabel ini mengonfirmasi bahwa metode deteksi gestur menggunakan *YOLOv8* telah mencapai performa yang reliabel untuk tujuan identifikasi gestur pelanggan.

3.3 Implementasi dan Pengujian Real-time Sistem

Model yang telah dilatih kemudian diekspor dan diintegrasikan menggunakan *streamlit* di implementasikan. Pengujian dilakukan secara real-time untuk menunjukkan hasil secara nyata. Hasil deteksi antarmuka *streamlit* dapat dilihat di bawah:



Gambar 6. Implementasi menggunakan *streamlit*

Hasil pengujian antarmuka *Streamlit* menunjukkan bahwa model deteksi gestur tangan berbasis *YOLOv8* mampu berjalan secara efektif dalam lingkungan waktu nyata. Sistem berhasil menampilkan proses visualisasi deteksi dari kamera perangkat dengan menampilkan kotak pembatas dan label gestur secara langsung pada layar. Pada contoh keluaran yang ditampilkan, sistem mengidentifikasi gestur “memesan” dengan tingkat keyakinan (*confidence score*) sebesar **0,66**, menandakan keberhasilan model dalam melakukan klasifikasi berdasarkan pola citra tangan pengguna. Keakuratan deteksi tersebut mengindikasikan bahwa proses pelatihan model dan pemrosesan data yang telah dilakukan sebelumnya menghasilkan struktur pembelajaran fitur yang baik.

Selain informasi deteksi, antarmuka juga menampilkan indikator kinerja berupa nilai *frames per second* (FPS) sebesar **5,3**. Nilai ini menggambarkan kemampuan sistem dalam memproses aliran video secara kontinu menggunakan perangkat dengan spesifikasi CPU. Walaupun FPS yang dihasilkan belum mencapai tingkat sangat tinggi, nilai tersebut sudah cukup untuk memenuhi kebutuhan pemantauan gerakan tangan dalam konteks interaksi pelanggan yang tidak menuntut pergerakan cepat. Hal ini sekaligus menunjukkan bahwa model dapat dioperasikan pada perangkat dengan spesifikasi menengah tanpa ketergantungan pada GPU eksternal.

Aplikasi ini juga menyediakan komponen pengaturan *inference* seperti ukuran citra input, ambang keyakinan, serta *IoU threshold*, sehingga pengguna dapat melakukan penyetelan sesuai kebutuhan performa. Fleksibilitas ini penting untuk menyesuaikan sistem terhadap kondisi pencahayaan, jarak kamera, atau kebutuhan kecepatan deteksi. Selain itu, fungsi kontrol kamera seperti *start*, *stop*, dan pengambilan tangkapan layar (*snapshot*) menambah kemudahan dalam proses pengamatan dan dokumentasi hasil pengujian. Maka dari itu, hasil uji coba melalui *Streamlit* menunjukkan bahwa sistem yang dibangun mampu menyajikan informasi visual deteksi gestur tangan secara jelas, stabil, dan responsif.

3.4 Analisa dan Pembahasan Hasil

Berdasarkan serangkaian pengujian hasil pengujian model *YOLOv8* terhadap data gestur tangan menunjukkan bahwa sistem mampu melakukan deteksi kelas secara akurat pada tiga kategori gestur, yaitu *konfirmasi*, *memesan*, dan *selesai*. Tingkat keberhasilan deteksi yang terlihat melalui keluaran aplikasi *Streamlit* memperlihatkan bahwa sistem mampu mengidentifikasi gestur “memesan” dengan tingkat keyakinan sebesar 0,66 pada kondisi pencahayaan tidak ideal. Temuan ini memperkuat indikasi bahwa model memiliki ketahanan terhadap variasi kondisi latar belakang serta perbedaan pose tangan pengguna. Selain itu, nilai *precision*, *recall*, dan *mean Average Precision (mAP)* yang diperoleh selama proses pelatihan memperlihatkan performa yang stabil, sehingga dapat disimpulkan bahwa model tidak hanya memahami pola bentuk tangan, tetapi juga mampu membedakan posisi tangan yang berdekatan antar kelas.

Secara umum, model menunjukkan pola peningkatan kinerja yang konsisten. Grafik *loss* memperlihatkan penurunan signifikan pada tahap awal pelatihan, yang kemudian diikuti dengan stabilisasi menuju epoch akhir. Tren tersebut mengindikasikan bahwa model mencapai proses konvergensi yang baik tanpa ditemukan indikasi *overfitting* yang berlebihan. Sementara itu, grafik *precision-recall* menampilkan wilayah dominasi nilai *precision*

pada rentang recall tinggi, yang menunjukkan bahwa model relatif jarang menghasilkan prediksi positif palsu (*false positive*). Fenomena ini berpengaruh terhadap optimasi hasil deteksi pada data uji, karena sistem mampu menjaga keseimbangan antara kepekaan dan ketelitian klasifikasi.

Salah satu indikator performa yang menarik adalah hasil *confusion matrix*, yang menunjukkan bahwa sebagian besar data uji terklasifikasi secara tepat. Nilai akurasi tertinggi berada pada kelas “konfirmasi” dan “memesan”, sedangkan kelas “selesai” menunjukkan penurunan prediksi benar akibat kesamaan struktur gestur dan sudut pengambilan gambar yang lebih variatif. Meskipun demikian, rata-rata keberhasilan klasifikasi antar kelas tetap berada pada tingkat yang memuaskan. Ketidakselarasan minor antar kelas juga dapat dipahami sebagai pengaruh langsung dari variasi dataset yang diambil dari kondisi nyata serta variasi skala objek pada citra.

Pengujian melalui antarmuka *Streamlit* memberikan gambaran kinerja sistem secara lebih praktis. Nilai FPS sebesar 5.3 menunjukkan bahwa proses inferensi dapat berjalan dengan lancar menggunakan prosesor CPU tanpa dukungan perangkat GPU. Dengan kata lain, sistem bersifat ekonomis dan mudah diimplementasikan pada perangkat komputasi umum. Real-time detection yang diperoleh membuktikan bahwa representasi fitur model tidak memerlukan sumber daya visual yang berlebihan. Keberhasilan pengujian ini memperkuat kesimpulan bahwa rancangan sistem praktis, responsif, dan siap untuk diintegrasikan pada lingkungan layanan pelanggan berbasis gestur tangan.

Secara keseluruhan, hasil penelitian ini menegaskan bahwa pendekatan berbasis *YOLOv8* memiliki potensi besar sebagai solusi pengenalan gestur tangan otomatis. Kombinasi antara akurasi deteksi yang tinggi, kemampuan bekerja pada kondisi lingkungan nyata, serta performa proses inferensi yang stabil menjadikan sistem ini relevan untuk dikembangkan lebih lanjut ke arah implementasi industri dalam bidang pelayanan otomatis. Temuan ini juga membuka peluang untuk meningkatkan fungsi sistem menuju klasifikasi multi-gestur lain, integrasi dengan *robotic platform*, atau pembelajaran multimodal menggunakan data video berurutan untuk mengatasi pergerakan gestur dinamis.

4. SIMPULAN

Berdasarkan hasil implementasi dan analisis pengujian sistem klasifikasi pola citra dalam deteksi gestur tangan pelanggan menggunakan metode *YOLOv8*, dapat ditarik beberapa simpulan sebagai berikut:

1. Penelitian ini berhasil menghasilkan model klasifikasi gestur tangan berbasis *YOLOv8* yang mampu mengenali tiga kategori gestur pelanggan secara efektif pada lingkungan pengujian nyata. Sistem menunjukkan konsistensi performa deteksi, baik pada citra uji individual maupun melalui pengujian *real-time* menggunakan antarmuka *Streamlit*.
2. Kinerja model memperlihatkan tingkat ketepatan yang tinggi, ditunjukkan oleh capaian akurasi rata-rata 92,33%. Hasil ini menunjukkan bahwa proses pelatihan, pemilihan parameter, serta struktur dataset yang digunakan telah cukup efektif dalam membangun representasi visual sistem.
3. Kelebihan utama model terletak pada proses prediksi yang berlangsung cepat, dukungan *pretrained weight*, serta kemampuan melakukan klasifikasi tanpa memerlukan komputasi tinggi. Faktor tersebut membuat sistem memiliki potensi penerapan langsung dalam layanan berbasis komputer visi.
4. Kekurangan sistem terutama terlihat pada variasi citra tertentu yang menunjukkan ketidakstabilan deteksi, khususnya pada kondisi pencahayaan rendah dan jarak objek yang terlalu dekat atau jauh dari kamera. Variasi visual tersebut mempengaruhi konsistensi nilai *confidence* pada sebagian keluaran.
5. Penelitian ini masih menyisakan peluang pengembangan lebih lanjut, di antaranya memperluas jumlah kelas gestur, melakukan pelatihan menggunakan dataset dinamis berbasis video, meningkatkan kualitas *frame rate* sistem *real-time*, serta mengintegrasikan model dengan lingkungan layanan untuk tujuan implementasi industri.

5. SARAN

Berdasarkan hasil temuan pada penelitian ini, diharapkan peneliti selanjutnya untuk memperluas keragaman dataset, terutama pada aspek pencahayaan, latar belakang, serta sudut pengambilan gambar agar kemampuan generalisasi model *YOLOv8* dapat meningkat terhadap variasi lingkungan yang lebih kompleks. Pengembangan juga dapat diarahkan pada penggunaan data video berurutan sehingga proses klasifikasi tidak hanya bertumpu pada citra statis, melainkan mampu mengenali pola transisi gestur secara alami. Selain itu, penelitian mendatang perlu mempertimbangkan penerapan teknik optimasi model, seperti *quantization* atau *pruning*, untuk meningkatkan kecepatan inferensi dalam aplikasi *real-time*. Penambahan kelas gestur baru yang relevan dengan konteks pelayanan juga menjadi peluang penelitian berikutnya, dengan catatan perlu ditopang oleh peningkatan jumlah data berlabel yang memadai. Terakhir, evaluasi lanjutan dapat dilakukan dengan membandingkan performa *YOLOv8* terhadap arsitektur lain guna memperoleh pemahaman komparatif yang lebih luas terkait efisiensi, akurasi, dan kebutuhan komputasi dalam tugas pendeteksian gestur tangan.

DAFTAR PUSTAKA

- [1] I. I. Arifah, F. N. Fajri, G. Qorik, and O. Pratamasunu, “Deteksi Tangan Otomatis Pada Video Percakapan Bahasa Isyarat Indonesia Menggunakan Metode YOLO Dan CNN,” vol. 6, no. 2, pp. 171–176, 2022.
- [2] F. Teknologi and I. Universitas, “ISYARAT BERDASARKAN GERAK TUBUH SECARA REAL TIME,” vol. 8, no. 2, pp. 300–304, 2023.
- [3] J. Medellu, A. Sambul, and A. S. M. Lumenta, “Hand Gesture Detection Application in Sign Language,” vol. 17, no. 4, pp. 285–296, 2022.
- [4] K. Karina and M. Andrei, “HaGRID – HAnd Gesture Recognition Image Dataset”.
- [5] A. Nuzhdin, A. Nagaev, A. Sautin, A. Kapitanov, and K. Kvanchiani, “HaGRIDv2: 1M Images for Static and Dynamic Hand Gesture Recognition”.
- [6] I. Fatahna, P. Desi, K. Sari, A. N. Kamilah, R. Wulanningrum, and C. Utomo, “Implementasi Computer Vision Terhadap Jenis Kualitas Pisang Susu Menggunakan Metode YOLOv8n Berbasis WebApps,” vol. 4, pp. 1–10, 2025.
- [7] M. T. Informatika, I. Informatika, and B. Lampung, “Evaluasi Kinerja Model YOLOv8 dalam Deteksi Kesegaran Buah,” pp. 357–368.