

Fika Megawati

Mochammad Akbar Kurniawan 221080200074 BAB.docx

 PRISTIWANTO

 Kampus 2

 Perpustakaan

Document Details

Submission ID

trn:oid::1:3657509174

Submission Date

Sep 23, 2026, 9:28 AM GMT+7

Download Date

Sep 23, 2026, 9:41 AM GMT+7

File Name

Mochammad_Akbar_Kurniawan_221080200074_BAB.docx

File Size

10.3 MB

14 Pages

5,854 Words

38,335 Characters

16% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- Bibliography
- Quoted Text

Top Sources

- 21%  Internet sources
- 17%  Publications
- 16%  Submitted works (Student Papers)

Integrity Flags

0 Integrity Flags for Review

No suspicious text manipulations found.

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.

Top Sources

- 21%  Internet sources
- 17%  Publications
- 16%  Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Student papers
Universitas Muhammadiyah Sidoarjo	
	14%
2	Internet
ejurnal.stmik-budidarma.ac.id	
	2%

Implementation of the YOLOv8 Method for Restaurant Table Condition and Customer Activity Detection

[Penerapan Metode YOLOv8 untuk Deteksi Kondisi Meja dan Aktivitas Pengunjung pada Rumah Makan]

Mochammad Akbar Kurniawan¹⁾, Rohman Dijaya^{*2)}

¹⁾ Program Studi Teknik Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

²⁾ Program Studi Teknik Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

*Email Penulis Korespondensi: rohman.dijaya@umsida.ac.id

Abstract. The culinary industry continues to grow, increasing the demand for fast and efficient service. One issue still encountered in restaurants is manual table-condition monitoring, which may delay customer service. This study implements and compares YOLOv8n, YOLOv8s, and YOLOv8m for real-time detection of table occupancy and table conditions. The dataset consists of 500 images captured using a webcam at Soto Madura Pojok Terminal Restaurant and annotated in Roboflow into three classes: Empty Table, Occupied Table, and Dirty Table. The dataset was divided by recording session into 300 training images, 96 validation images, and 104 testing images. The models were trained using 640×640 pixel images, a batch size of 16, a maximum of 150 epochs, and early stopping. Performance was evaluated using Precision, Recall, mAP@50, and mAP@50–95. The test results showed that YOLOv8m achieved the best overall performance, with a Precision of 95.82%, Recall of 94.95%, mAP@50 of 97.95%, and mAP@50–95 of 94.22%. YOLOv8m has approximately 25.84 million parameters, required 68.10 minutes of training, and achieved an inference time of 21.1 ms per image on an NVIDIA Tesla T4 GPU. The best performing model was implemented in a dashboard to display table counts by category and restaurant occupancy status as quiet, normal, or crowded. The results indicate that YOLOv8m can support automated table-condition monitoring in the restaurant environment studied.

Keywords - Computer Vision, Object Detection, Real-Time, Restaurant, YOLOv8

Abstrak. Industri kuliner terus berkembang sehingga meningkatkan kebutuhan akan pelayanan yang cepat dan efisien. Salah satu permasalahan yang masih dijumpai pada rumah makan adalah pemantauan kondisi meja secara manual yang dapat menyebabkan keterlambatan pelayanan kepada pelanggan. Penelitian ini menerapkan dan membandingkan YOLOv8n, YOLOv8s, dan YOLOv8m untuk mendeteksi okupansi serta kondisi meja secara real-time. Dataset terdiri atas 500 citra yang diperoleh menggunakan webcam di Rumah Makan Soto Madura Pojok Terminal dan dianotasi melalui Roboflow ke dalam tiga kelas, yaitu Meja Kosong, Meja Terisi, dan Meja Kotor. Dataset dibagi berdasarkan sesi perekaman menjadi 300 citra training, 96 citra validation, dan 104 citra testing. Model dilatih menggunakan ukuran citra 640×640 piksel, batch size 16, maksimum 150 epoch, serta mekanisme early stopping. Kinerja model dievaluasi menggunakan Precision, Recall, mAP@50, dan mAP@50–95. Hasil pengujian menunjukkan bahwa YOLOv8m memberikan performa terbaik dengan Precision 95,82%, Recall 94,95%, mAP@50 97,95%, dan mAP@50–95 94,22%. YOLOv8m memiliki sekitar 25,84 juta parameter, membutuhkan waktu pelatihan 68,10 menit, dan menghasilkan waktu inferensi 21,1 ms per citra pada GPU NVIDIA Tesla T4. Model terbaik kemudian diimplementasikan pada dashboard untuk menampilkan jumlah meja berdasarkan kategori serta status okupansi rumah makan berupa sepi, normal, atau ramai. Hasil penelitian menunjukkan bahwa YOLOv8m dapat mendukung pemantauan kondisi meja secara otomatis pada lingkungan rumah makan yang diteliti.

Kata Kunci - Computer Vision, Deteksi Objek, Real-Time, Rumah Makan, YOLOv8

I. PENDAHULUAN

Industri kuliner menjadi salah satu sektor usaha yang terus mengalami perkembangan pesat di Indonesia. Berdasarkan data Statistik Penyediaan Makanan dan Minuman Tahun 2023, tercatat sebanyak 4,85 juta unit usaha penyedia makanan dan minuman, yang berarti terjadi peningkatan sekitar 21,13% dibandingkan tahun 2016[1]. Dari jumlah tersebut, sekitar 24,75% merupakan usaha restoran dan rumah makan. Peningkatan jumlah rumah makan menunjukkan bahwa kebutuhan masyarakat terhadap layanan penyedia makanan semakin tinggi sehingga pelaku usaha dituntut mampu memberikan pelayanan yang cepat, efisien, dan berkualitas[2]. Salah satu aspek yang memengaruhi kualitas pelayanan adalah kecepatan dalam menyediakan meja yang siap digunakan pelanggan. Namun, pada rumah makan yang masih mengandalkan pemantauan kondisi meja secara manual, proses identifikasi meja tersedia maupun meja yang memerlukan pembersihan bergantung pada pengamatan petugas dan berpotensi menimbulkan keterlambatan pelayanan terutama pada jam operasional yang padat. Kondisi ini dapat menyebabkan pelanggan menunggu lama untuk mendapatkan tempat duduk [3]. Oleh karena itu, diperlukan suatu sistem yang

Copyright © Universitas Muhammadiyah Sidoarjo. This preprint is protected by copyright held by Universitas Muhammadiyah Sidoarjo and is distributed under the Creative Commons Attribution License (CC BY). Users may share, distribute, or reproduce the work as long as the original author(s) and copyright holder are credited, and the preprint server is cited per academic standards.

Authors retain the right to publish their work in academic journals where copyright remains with them. Any use, distribution, or reproduction that does not comply with these terms is not permitted.

mampu melakukan pemantauan kondisi meja secara otomatis sehingga informasi mengenai kondisi meja dapat diperoleh secara cepat dan akurat serta mendukung peningkatan kualitas pelayanan pada rumah makan[4].

Penelitian ini dilakukan di Rumah Makan Soto Madura Pojok Terminal sebagai lokasi pengambilan data. Pemilihan lokasi tersebut didasarkan pada kondisi operasional rumah makan yang memiliki perubahan tingkat okupansi dan kondisi meja selama jam pelayanan. Kondisi tersebut memungkinkan diperolehnya variasi objek dalam tiga kategori, yaitu meja kosong, meja terisi, dan meja kotor. Dengan menggunakan kondisi operasional nyata sebagai sumber data, sistem yang dikembangkan dapat diuji untuk mendeteksi kondisi meja pada situasi yang lebih sesuai dengan penggunaan sebenarnya di lingkungan rumah makan.

Perkembangan *Artificial Intelligence* (AI) khususnya *Computer Vision*, memberikan peluang untuk mengatasi permasalahan tersebut melalui proses deteksi objek secara otomatis[5]. *Computer Vision* memungkinkan komputer mengenali objek pada citra maupun video sehingga mampu menggantikan proses pengamatan yang sebelumnya dilakukan secara manual. Dalam bidang deteksi objek, *You Only Look Once* (YOLO) banyak digunakan karena mampu memproses citra secara cepat sekaligus mempertahankan tingkat ketepatan deteksi yang tinggi. Algoritma ini menggunakan pendekatan *single-stage object detection* sehingga proses klasifikasi dan prediksi lokasi objek dilakukan dalam satu kali komputasi, menjadikannya sesuai untuk aplikasi *real-time*[6]. Salah satu versi YOLO yang banyak digunakan dalam penelitian deteksi objek adalah YOLOv8, dikembangkan oleh *Ultralytics* menggunakan framework PyTorch[7]. YOLOv8 menawarkan peningkatan performa dibandingkan generasi sebelumnya melalui arsitektur yang lebih efisien, keseimbangan antara kecepatan inferensi dan akurasi deteksi, serta fleksibilitas implementasi pada perangkat berbasis CPU maupun GPU[8]. Selain itu, karakteristik kecepatan inferensi dan akurasi deteksi yang dimiliki YOLOv8 menjadikannya relevan untuk dikembangkan pada aplikasi pemantauan berbasis video yang membutuhkan pemrosesan secara *real-time*[9].

Penelitian terkait penerapan *Computer Vision* dan algoritma YOLO untuk pemantauan objek serta tingkat okupansi telah dilakukan dalam berbagai konteks. Hidayah et al. [10] mengintegrasikan YOLOv5 dan OpenCV untuk mendeteksi kendaraan sekaligus mengidentifikasi ketersediaan area parkir secara *real-time*. Sistem diuji pada tiga kondisi, yaitu kosong, terisi sebagian, dan penuh, serta mampu mendeteksi 31 kendaraan dan 20 slot parkir dengan persentase perhitungan kendaraan sebesar 100%. Meskipun demikian, penelitian tersebut masih berfokus pada konteks area parkir dan belum diterapkan pada klasifikasi kondisi meja di lingkungan rumah makan. Selanjutnya, Güler dan Musa [11] mengembangkan sistem deteksi okupansi meja restoran menggunakan YOLOv8 pada *custom dataset* sebanyak 792 citra. Model memperoleh *Precision* sebesar 0,998, *Recall* 1,000, *mAP@0.5* sebesar 0,997, dan *mAP@0.5:0.95* sebesar 0,985. Sistem tersebut juga mengintegrasikan deteksi manusia dan analisis *time-series* untuk memantau serta memprediksi tingkat okupansi meja. Namun, penelitian ini lebih berfokus pada deteksi meja dan jumlah orang yang menggunakan meja, sehingga belum mengklasifikasikan kondisi meja ke dalam kategori Meja Kosong, Meja Terisi, dan Meja Kotor maupun membandingkan beberapa varian YOLOv8. Amanullah et al. [12] menerapkan YOLO pada lingkungan restoran untuk mendeteksi pelanggan dan makanan secara *real-time*, dengan akurasi sebesar 85% untuk pelanggan dan 83% untuk makanan. Berbagai penelitian tersebut menunjukkan bahwa algoritma YOLO memiliki potensi untuk mendukung deteksi objek dan pemantauan kondisi secara otomatis, termasuk pada lingkungan yang membutuhkan pemrosesan *real-time*.

Meskipun telah menunjukkan hasil yang baik, penelitian terdahulu masih memiliki keterbatasan dalam penerapan deteksi kondisi meja pada rumah makan. Penelitian Güler dan Musa berfokus pada deteksi meja dan jumlah orang yang menggunakannya, sedangkan penelitian pada lingkungan restoran lainnya lebih menitikberatkan pada deteksi pelanggan dan makanan. Berdasarkan kajian tersebut, belum ditemukan penelitian yang secara khusus membandingkan YOLOv8n, YOLOv8s, dan YOLOv8m untuk mengklasifikasikan kondisi meja ke dalam tiga kategori, yaitu Meja Kosong, Meja Terisi, dan Meja Kotor, sekaligus mengintegrasikan model terbaik ke dalam dashboard monitoring yang menampilkan jumlah meja dan tingkat okupansi rumah makan. Kebaruan penelitian ini terletak pada perbandingan tiga varian YOLOv8 untuk deteksi tiga kondisi meja serta integrasi model terbaik ke dalam sistem monitoring okupansi berbasis kamera secara *real-time*. Pendekatan tersebut penting untuk menghasilkan sistem yang tidak hanya mampu mengenali kondisi meja, tetapi juga memberikan informasi okupansi yang dapat digunakan sebagai pendukung pemantauan operasional rumah makan.


Berdasarkan *research gap* tersebut, penelitian ini bertujuan menerapkan dan membandingkan YOLOv8n, YOLOv8s, dan YOLOv8m untuk mendeteksi kondisi meja pada rumah makan menggunakan kamera webcam secara *real-time*. Performa model dievaluasi menggunakan *Precision*, *Recall*, *mAP@50*, dan *mAP@50–95*, kemudian model terbaik diimplementasikan pada dashboard yang menampilkan jumlah Meja Kosong, Meja Terisi, dan Meja Kotor serta tingkat okupansi rumah makan. Dalam penelitian ini, aktivitas pengunjung direpresentasikan melalui tingkat okupansi berdasarkan jumlah meja yang terdeteksi terisi, yang selanjutnya digunakan untuk menentukan status rumah makan berupa sepi, normal, atau ramai. Dengan demikian, penelitian ini diharapkan dapat menghasilkan sistem monitoring kondisi meja berbasis *Computer Vision* yang mendukung penerapan konsep *smart restaurant* dan membantu meningkatkan efisiensi pelayanan rumah makan[13].

II. METODE

2.1 Tahapan Penelitian

Penelitian ini menerapkan algoritma YOLOv8 sebagai metode deteksi berbasis *deep learning*. Dataset diperoleh dari rekaman video menggunakan kamera webcam di Rumah Makan Soto Madura Pojok Terminal, kemudian diekstraksi menjadi citra. Setiap citra dianotasi menggunakan *bounding box* ke dalam tiga kelas, yaitu Meja Kosong, Meja Terisi, dan Meja Kotor, selanjutnya dikonversi ke dalam format YOLO. Selanjutnya, dataset dibagi menjadi data pelatihan, validasi, dan pengujian untuk proses pelatihan dan evaluasi model. Penelitian membandingkan tiga varian YOLOv8, yaitu YOLOv8n, YOLOv8s, dan YOLOv8m, menggunakan metrik *Precision*, *Recall*, $mAP@50$, dan $mAP@50-95$ [14].

YOLOv8n merupakan varian nano dengan ukuran model paling ringan dan jumlah parameter paling sedikit sehingga memiliki kebutuhan komputasi yang relatif rendah. YOLOv8s merupakan varian small dengan kapasitas model lebih besar dibandingkan YOLOv8n dan dirancang untuk mencapai keseimbangan antara tingkat akurasi dan kebutuhan komputasi. Sementara itu, YOLOv8m merupakan varian medium dengan kapasitas model dan jumlah parameter yang lebih besar sehingga mampu mempelajari karakteristik objek yang lebih kompleks, tetapi membutuhkan sumber daya komputasi dan waktu pelatihan yang lebih besar. Perbandingan ketiga varian tersebut menjadi bagian utama penelitian untuk menentukan model yang paling tepat untuk digunakan pada sistem deteksi kondisi meja secara real-time. Aktivitas pengunjung dalam penelitian ini direpresentasikan melalui tingkat okupansi yang dihitung berdasarkan proporsi meja terisi terhadap jumlah keseluruhan meja yang terdeteksi.



Gambar 1. Tahapan Penelitian

Gambar 1 merupakan alur penelitian dimulai dari pengambilan data pada Rumah Makan Soto Madura Pojok Terminal. Data yang diperoleh selanjutnya diolah melalui beberapa tahapan, yaitu *pre-processing*, anotasi, dan pembagian dataset menjadi data pelatihan, validasi, dan pengujian. Dataset yang telah diproses digunakan untuk melatih tiga varian model YOLOv8, yaitu YOLOv8n (nano), YOLOv8s (small), dan YOLOv8m (medium). Selanjutnya, setiap model dievaluasi menggunakan metrik *Precision*, *Recall*, $mAP@50$, dan $mAP@50-95$, serta dibandingkan berdasarkan jumlah parameter, waktu pelatihan, dan waktu inferensi. Model dengan performa terbaik kemudian dipilih untuk diimplementasikan pada sistem monitoring kondisi meja secara real-time. Tahap akhir penelitian berupa pengujian sistem untuk memastikan proses deteksi, klasifikasi kondisi meja, perhitungan tingkat okupansi, dan penentuan status keramaian rumah makan dapat berjalan sesuai kebutuhan.

2.2 Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data primer yang diperoleh melalui perekaman video secara langsung menggunakan kamera webcam beresolusi HD dengan ukuran 1920x1080 dan kecepatan perekaman 30 fps di Rumah Makan Soto Madura Pojok Terminal. Perekaman dilakukan dalam tiga sesi pada waktu yang berbeda dengan durasi 30–60 menit untuk memperoleh variasi kondisi operasional, seperti jumlah pengunjung, tingkat okupansi, dan kondisi meja. Video kemudian diekstraksi menjadi citra dengan interval 20-30 detik. Citra yang buram, duplikat, dan tidak menampilkan objek meja secara jelas diseleksi, sehingga diperoleh 500 citra. Selanjutnya, setiap citra dianotasi menggunakan *bounding box* ke dalam tiga kelas, yaitu Meja Kosong, Meja Terisi, dan Meja Kotor, kemudian diekspor dalam format YOLO untuk digunakan dalam pelatihan, validasi, dan pengujian model YOLOv8.

2.3 Pengolahan Data

2.3.1 Pre-processing

Tahap *pre-processing* dilakukan untuk mempersiapkan dataset sebelum digunakan pada model YOLOv8. Tahap ini meliputi ekstraksi frame menggunakan fitur *Extract Frames* pada Roboflow, seleksi citra yang buram atau duplikat, serta proses *Auto-Orient* untuk menyeragamkan orientasi gambar. Selanjutnya, citra di-*resize* menjadi 640×640 piksel menggunakan metode *Fit (white edges)* dengan tetap mempertahankan rasio aspek[15].



Gambar 2. Normalisasi Data

2.3.2 Pelabelan dan Anotasi

Setelah proses *pre-processing* selesai, citra pada dataset kemudian diberi anotasi melalui platform Roboflow dengan menandai setiap objek menggunakan *bounding box*, yaitu memberikan kotak pembatas pada setiap objek meja yang terdapat pada citra sesuai dengan kondisi sebenarnya. Setiap objek diberi label ke dalam tiga kelas, yaitu *Meja Kosong*, *Meja Terisi*, dan *Meja Kotor*. Proses anotasi dilakukan secara manual untuk memastikan setiap objek memiliki posisi dan label yang sesuai. Hasil anotasi kemudian diekspor dalam format YOLO, di mana setiap citra memiliki berkas anotasi berekstensi *.txt* yang berisi informasi koordinat *bounding box* dan identitas kelas objek[16]. Dataset yang telah melalui proses anotasi kemudian digunakan untuk pembagian data, pelatihan, validasi, dan pengujian model YOLOv8.




Gambar 3. Proses Anotasi Data

Kelas *Meja Kosong* didefinisikan sebagai meja yang tidak digunakan oleh pengunjung dan tidak terdapat peralatan makan yang menunjukkan aktivitas penggunaan. Kelas *Meja Terisi* merupakan meja yang sedang digunakan oleh pengunjung. Sementara itu, kelas *Meja Kotor* merupakan meja yang tidak ditempati pengunjung dan masih terdapat sisa peralatan makan yang belum dibersihkan. Penentuan ketiga kelas tersebut dilakukan secara konsisten pada seluruh proses anotasi untuk menjaga kualitas dataset.

COLOR	CLASS NAME	COUNT	MODIFY
●	Meja Kosong	3,422	☐
●	Meja Kotor	1,487	☐
●	Meja Terisi	4,891	☐

Gambar 4. Jumlah Anotasi per Kelas

Gambar 4 menunjukkan jumlah anotasi pada masing-masing kelas dalam dataset penelitian. Dataset yang digunakan terdiri atas tiga kelas, yaitu Meja Kosong, Meja Terisi, dan Meja Kotor. Hasil proses anotasi menghasilkan 3.422 objek untuk kelas Meja Kosong, 4.091 objek untuk kelas Meja Terisi, dan 1.487 objek untuk kelas Meja Kotor. Jumlah anotasi tersebut merepresentasikan banyaknya objek meja yang terdapat pada seluruh citra, sehingga setiap citra dapat memuat beberapa objek sekaligus sesuai dengan jumlah meja yang terdeteksi pada area pengambilan gambar.




Gambar 5. Augmentasi Dataset

Untuk menambah variasi data pelatihan serta mengurangi *overfitting*, dilakukan augmentasi menggunakan platform Roboflow[17]. Augmentasi diterapkan hanya pada data pelatihan (training set) dengan menghasilkan tiga variasi citra pada setiap data pelatihan (*Outputs per training example* = 3). Teknik augmentasi yang digunakan meliputi horizontal flip, grayscale pada 50% citra, penyesuaian brightness pada rentang -50% hingga +50%, exposure pada rentang -25% hingga +25%, blur hingga 2 piksel, serta penambahan noise hingga 2% piksel. Sementara itu, data validasi dan pengujian tetap menggunakan data asli tanpa augmentasi sehingga proses evaluasi dilakukan menggunakan citra asli[18].

2.3.3 Pembagian Dataset

Dataset dibagi menggunakan platform Roboflow. Dataset awal yang terdiri atas 500 citra dibagi menjadi tiga subset, yaitu data pelatihan, validasi, dan pengujian. Skenario pembagian dataset yang digunakan adalah 60% : 19,2% : 20,8%, masing-masing terdiri atas 300 citra data pelatihan, 96 citra data validasi, dan 104 citra data pengujian. Pembagian tersebut dilakukan berdasarkan sumber sesi perekaman dan tidak dilakukan secara acak pada tingkat frame untuk mengurangi kemiripan temporal antara data pelatihan, validasi, dan pengujian.. Seluruh citra dari sesi satu digunakan sebagai data pelatihan, sesi dua digunakan sebagai data validasi, dan sesi tiga digunakan sebagai data pengujian. Dengan demikian, frame dari satu sesi video tidak digunakan pada lebih dari satu subset. Selanjutnya, proses augmentasi diterapkan hanya pada data pelatihan dengan menghasilkan tiga variasi citra untuk setiap data, sehingga jumlah data pelatihan meningkat menjadi 900 citra. Sementara itu, data validasi dan data pengujian tidak mengalami augmentasi sehingga tetap berjumlah 96 citra dan 104 citra. Dengan demikian, total dataset yang digunakan dalam proses pelatihan dan evaluasi menjadi 1.100 citra.




Gambar 6. Pembagian Dataet

Data pelatihan digunakan untuk melatih model YOLOv8 melalui proses pembelajaran terhadap karakteristik setiap kelas objek. Data pengujian digunakan untuk menilai kinerja akhir model secara objektif menggunakan data yang belum pernah terlibat dalam proses pelatihan atau validasi, dan data validasi memantau kinerja model selama proses pelatihan dan membantu menentukan model terbaik.

2.4 Pelatihan Model

Pelatihan model menggunakan YOLOv8 pada Google Colab yang menggunakan GPU NVIDIA Tesla T4. Penelitian membandingkan tiga varian, yaitu YOLOv8n, YOLOv8s, dan YOLOv8m, menggunakan *pre-trained weights* dengan parameter 150 *epoch*, *batch size* 16, ukuran citra 640 × 640 piksel, dan *patience* 20[19]. Model terbaik dari setiap varian disimpan dalam berkas *best.pt* untuk selanjutnya dievaluasi dan dibandingkan berdasarkan performanya.



Gambar 7. Flowchart Pelatihan Sistem Deteksi Kondisi Meja

2.5 Evaluasi Model

Evaluasi performa model dilakukan menggunakan mekanisme evaluasi bawaan framework Ultralytics YOLOv8. Evaluasi dilakukan terhadap model YOLOv8n, YOLOv8s, dan YOLOv8m menggunakan dataset validasi dan dataset pengujian yang telah dipisahkan sebelumnya. Framework YOLOv8 secara otomatis menghasilkan beberapa metrik evaluasi, yaitu Precision, Recall, mAP@50, dan mAP@50–95, serta confusion matrix dan kurva evaluasi untuk menganalisis kemampuan deteksi dan klasifikasi model.[20]. Precision digunakan untuk mengukur ketepatan prediksi positif yang dihasilkan model, sedangkan Recall digunakan untuk mengukur kemampuan model dalam mendeteksi objek yang terdapat pada ground truth. mAP@50 menunjukkan rata-rata Average Precision pada IoU 0,50, sedangkan mAP@50–95 merupakan rata-rata Average Precision pada rentang IoU 0,50 hingga 0,95 dengan interval 0,05.

Nilai Precision dihitung menggunakan Persamaan (1)

$$Precision = \frac{TP}{TP+F}$$

Nilai Recall dihitung menggunakan Persamaan (2)

$$Recall = \frac{TP}{TP+FN}$$

dengan:

- TP (*True Positive*) : jumlah objek yang berhasil dideteksi dengan benar.
- FP (*False Positive*) : jumlah objek yang terdeteksi sebagai objek target, tetapi sebenarnya bukan objek target.
- FN (*False Negative*) : jumlah objek target yang tidak berhasil dideteksi oleh model.


Nilai mAP dihitung menggunakan Persamaan (3)

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

dengan:

- mAP (mean Average Precision): nilai rata-rata Average Precision (AP) dari seluruh kelas yang dideteksi.
- AP (Average Precision): nilai luas area di bawah kurva Precision-Recall untuk suatu kelas.
- N: jumlah kelas objek yang digunakan dalam penelitian.
- AP_i : nilai Average Precision pada kelas ke-i

Selain metrik akurasi deteksi, evaluasi juga mempertimbangkan aspek komputasi berupa jumlah parameter, waktu pelatihan, dan waktu inferensi. Jumlah parameter digunakan untuk menunjukkan ukuran model, waktu pelatihan menunjukkan kebutuhan komputasi selama proses pembelajaran, sedangkan waktu inferensi digunakan untuk mengetahui efisiensi model dalam menghasilkan prediksi.



Gambar 8. Flowchart Evaluasi Sistem Deteksi Kondisi Meja

2.6 Pengujian Sistem

Pengujian sistem menerapkan metode *black-box testing* untuk menguji apakah setiap fungsi pada sistem pemantauan kondisi meja telah bekerja sesuai dengan rancangan dan kebutuhan yang ditetapkan. Pengujian dilakukan melalui beberapa skenario, termasuk penerimaan *video streaming* dari kamera webcam, deteksi kondisi meja secara *real-time* menggunakan model YOLOv8, serta penampilan hasil deteksi pada dashboard sistem[21]. Selain itu, dilakukan pengujian terhadap fungsi perhitungan jumlah meja berdasarkan tiga kategori, yaitu Meja Kosong, Meja Terisi, dan Meja Kotor. Berdasarkan hasil pengujian, setiap fitur yang diimplementasikan pada sistem mampu berfungsi sesuai rancangan dan memberikan output sebagaimana yang diharapkan dalam penelitian.

III HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan dan Evaluasi Model

3.1.1 Hasil Pelatihan Model

Model dilatih menggunakan algoritma YOLOv8 dengan membandingkan varian YOLOv8n, YOLOv8s, dan YOLOv8m. Pada proses pelatihan, digunakan ukuran citra 640×640 piksel, *batch size* 16, dan maksimum 150 *epoch* dengan mekanisme *Early Stopping* (*patience* = 20).

Tabel 1. Perbandingan Hasil Pelatihan Model YOLOv8


Model	Max Epoch	Berhenti pada Epoch	Epoch Terbaik	Waktu (Menit)
YOLOv8n	150	108	88	29.22
YOLOv8s	150	88	68	28.02
YOLOv8m	150	99	79	68.10

Berdasarkan Tabel 1, proses pelatihan dilakukan dengan maksimum 150 epoch untuk setiap varian model YOLOv8. Namun, seluruh model menerapkan mekanisme Early Stopping (*patience* = 20), sehingga proses pelatihan berhenti sebelum mencapai jumlah epoch maksimum ketika tidak terdapat peningkatan performa selama 20 epoch berturut-turut. Model YOLOv8n berhenti pada epoch ke-108 dengan model terbaik diperoleh pada epoch ke-88 dan waktu pelatihan selama 29,22 menit. Model YOLOv8s berhenti pada epoch ke-88 dengan epoch terbaik ke-68 serta membutuhkan waktu pelatihan 28,02 menit. Sementara itu, YOLOv8m berhenti pada epoch ke-99 dengan epoch terbaik ke-79 dan memerlukan waktu pelatihan paling lama, yaitu 68,10 menit. Perbedaan waktu pelatihan tersebut dipengaruhi oleh kompleksitas arsitektur dan jumlah parameter pada masing-masing model, di mana YOLOv8m memiliki ukuran model yang lebih besar sehingga membutuhkan waktu komputasi lebih lama dibandingkan YOLOv8n dan YOLOv8s.

Tabel 2. Perbandingan Hasil Pelatihan Keseluruhan Model

Model	Parameter	GFLOPs	Inference Time	Precision (%)	Recall (%)	mAP@0.5 (%)	mAP@0.5:0.95 (%)
YOLOv8n	3.01 juta	8.1	6.9 ms	76.89	86.43	88.99	80.68
YOLOv8s	11.13 juta	28.4	9.9 ms	84.80	89.48	92.58	86.13
YOLOv8m	25.84 juta	78.7	22.2 ms	93.64	88.57	95.65	88.57

Selama pelatihan, kinerja model dipantau menggunakan data validasi sebanyak 96 citra yang telah dipisahkan dari data pelatihan dan data pengujian. Data validasi digunakan untuk mengevaluasi perkembangan performa model pada setiap epoch serta menentukan bobot terbaik yang akan digunakan pada tahap pengujian. Data validasi tidak diberikan augmentasi sehingga tetap menggunakan citra asli. Berdasarkan Tabel 2, ketiga varian YOLOv8 menunjukkan perbedaan baik dari sisi performa deteksi maupun kompleksitas komputasi. YOLOv8n merupakan model paling ringan dengan 3,01 juta parameter dan 8,1 GFLOPs serta waktu inferensi 6,9 ms per citra. Model ini memperoleh Precision sebesar 76,89%, Recall 86,43%, mAP@0.5 88,99%, dan mAP@0.5:0.95 80,68%. YOLOv8s memiliki 11,13 juta parameter dan 28,4 GFLOPs dengan waktu inferensi 9,9 ms. Model ini menghasilkan Precision 84,80%, Recall 89,48%, mAP@0.5 92,58%, dan mAP@0.5:0.95 86,13%. Sementara itu, YOLOv8m memiliki kompleksitas terbesar dengan 25,84 juta parameter dan 78,7 GFLOPs serta waktu inferensi 22,2 ms per citra. Pada data validasi, YOLOv8m memperoleh Precision tertinggi sebesar 93,64%, mAP@0.5 sebesar 95,65%, dan mAP@0.5:0.95 sebesar 88,57%, sedangkan Recall tertinggi diperoleh YOLOv8s sebesar 89,48%. Hasil tersebut menunjukkan adanya *trade-off* antara efisiensi komputasi dan performa deteksi. Semakin besar kapasitas model, jumlah parameter dan kebutuhan komputasi cenderung meningkat, yang pada eksperimen ini juga diikuti peningkatan waktu inferensi. Meskipun demikian, YOLOv8m menghasilkan performa validasi terbaik secara keseluruhan, sehingga bobot terbaiknya selanjutnya dievaluasi pada data pengujian untuk memastikan kemampuan model pada data yang tidak digunakan selama proses pelatihan dan validasi.



Gambar 9. Hasil Pelatihan Model Terbaik YOLOv8m (*loss, precision, recall, dan mAP*)


Berdasarkan Gambar 9, proses pelatihan model YOLOv8m menunjukkan tren yang stabil selama proses pembelajaran. Nilai *training loss* yang terdiri atas box loss, classification loss (cls loss), dan distribution focal loss (DFL loss) mengalami penurunan secara bertahap seiring bertambahnya *epoch*. Penurunan yang serupa juga terlihat

pada *validation loss*, yang menunjukkan bahwa model dapat mempelajari karakteristik data dengan baik tanpa mengalami peningkatan kesalahan yang signifikan pada data validasi. Seiring dengan menurunnya nilai *loss*, metrik evaluasi Precision, Recall, mAP@0.5, dan mAP@0.5:0.95 mengalami peningkatan hingga mencapai kondisi yang relatif stabil menjelang akhir proses pelatihan. Berdasarkan hasil evaluasi model terbaik, YOLOv8m memperoleh Precision 93,64%, Recall 88,57%, mAP@0.5 95,65%, dan mAP@0.5:0.95 88,57%. Nilai tersebut menunjukkan bahwa model mampu mendeteksi dan melokalisasi objek pada ketiga kelas, yaitu Meja Kosong, Meja Terisi, dan Meja Kotor.

Secara keseluruhan, kurva pelatihan menunjukkan bahwa model telah mencapai kondisi yang relatif stabil. Hal ini terlihat dari penurunan *loss* yang semakin landai serta metrik evaluasi yang cenderung stabil pada akhir pelatihan. Kondisi tersebut mengindikasikan bahwa model mampu bekerja dengan baik pada data validasi dan layak digunakan sebagai model terbaik pada tahap implementasi sistem deteksi kondisi meja berbasis *real-time*.

1) 3.1.2 Hasil Evaluasi Model

Evaluasi model dilakukan menggunakan *Confusion Matrix* untuk menganalisis kemampuan model dalam mengklasifikasikan kondisi meja ke dalam kelas Meja Kosong, Meja Terisi, dan Meja Kotor, sebagaimana ditunjukkan pada Gambar 10.



Gambar 10. Confusion Matric Model Terbaik YOLOv8m

Berdasarkan Gambar 10, *Confusion Matrix* menunjukkan hasil klasifikasi model terbaik YOLOv8m terhadap tiga kelas, yaitu Meja Kosong, Meja Kotor, dan Meja Terisi. Nilai yang berada pada diagonal utama menunjukkan jumlah objek yang diklasifikasikan secara tepat, sedangkan elemen di luar diagonal mencerminkan kesalahan model dalam membedakan satu kelas dengan kelas lainnya. (*misclassification*).

Pada kelas Meja Terisi, model mampu melakukan klasifikasi dengan baik, yang ditunjukkan oleh jumlah prediksi yang benar lebih banyak dibandingkan dengan prediksi yang salah. Hal ini menunjukkan bahwa karakteristik visual pada kelas tersebut lebih mudah dikenali oleh model. Sementara itu, pada kelas Meja Kosong dan Meja Kotor masih ditemukan beberapa kesalahan klasifikasi, kondisi tersebut diduga dipengaruhi oleh kemiripan karakteristik visual antara kelas Meja Kosong dan Meja Kotor, perubahan pencahayaan selama sesi pengamatan, serta occlusion akibat pengungjung atau objek lain yang menutupi sebagian permukaan meja.

Secara keseluruhan, *Confusion Matrix* menunjukkan bahwa model mampu mengklasifikasikan ketiga kelas dengan baik dengan tingkat kesalahan yang relatif rendah. Hasil ini sejalan dengan nilai evaluasi yang diperoleh pada model YOLOv8m, yaitu Precision sebesar 93,64%, Recall sebesar 88,57%, mAP@0.5 sebesar 95,65%, dan mAP@0.5:0.95 sebesar 88,57%, sehingga model dinilai sesuai untuk digunakan pada sistem deteksi kondisi meja berbasis *real-time*.

Tabel 3. Perbandingan Hasil Evaluasi Test Keseluruhan Model

Model	Parameter	GFLOPs	Inference Time	Precision (%)	Recall (%)	mAP@0.5 (%)	mAP@0.5:0.95 (%)
YOLOv8n	3.006.233	8.1	5.7 ms	94.65	92.94	97.28	90.62
YOLOv8s	11.126.745	28.4	9.1 ms	95.10	93.42	97.03	91.98
YOLOv8m	25.841.497	78.7	21.1 ms	95.82	94.95	97.95	94.22

Berdasarkan Tabel 3, evaluasi akhir dilakukan menggunakan *test set* yang terdiri atas 104 citra dengan 1.872 instance. Ketiga varian YOLOv8 menunjukkan performa deteksi yang tinggi, namun memiliki perbedaan dari sisi akurasi dan kebutuhan komputasi. YOLOv8n merupakan model paling ringan dengan 3.006.233 parameter dan kompleksitas sebesar 8,1 GFLOPs. Model ini memiliki waktu inferensi tercepat, yaitu 5,7 ms per citra, dengan *Precision* 94,65%, *Recall* 92,94%, *mAP@0.5* 97,28%, dan *mAP@0.5:0.95* 90,62%.

YOLOv8s memiliki 11.126.745 parameter dan 28,4 GFLOPs dengan waktu inferensi 9,1 ms per citra. Model ini memperoleh *Precision* 95,10%, *Recall* 93,42%, *mAP@0.5* 97,03%, dan *mAP@0.5:0.95* 91,98%. Dibandingkan YOLOv8n, YOLOv8s menunjukkan peningkatan pada *Precision*, *Recall*, dan *mAP@0.5:0.95*, meskipun nilai *mAP@0.5* sedikit lebih rendah. Sementara itu,


YOLOv8m memiliki kapasitas terbesar dengan 25.841.497 parameter dan 78,7 GFLOPs serta waktu inferensi 21,1 ms per citra. Model ini menghasilkan performa terbaik secara keseluruhan dengan *Precision* 95,82%, *Recall* 94,95%, *mAP@0.5* 97,95%, dan *mAP@0.5:0.95* 94,22%. Hasil tersebut menunjukkan bahwa peningkatan kapasitas model pada YOLOv8m mampu meningkatkan kemampuan deteksi dan ketepatan lokalisasi objek, meskipun membutuhkan sumber daya komputasi serta waktu inferensi yang lebih besar.

Secara keseluruhan, hasil pengujian menunjukkan adanya *trade-off* antara efisiensi komputasi dan performa deteksi. YOLOv8n menawarkan waktu inferensi paling rendah, sedangkan YOLOv8m memberikan akurasi terbaik dengan konsekuensi kompleksitas komputasi yang lebih tinggi. Berdasarkan performa pada *test set*, YOLOv8m dipilih sebagai model akhir untuk diimplementasikan pada sistem pemantauan kondisi meja secara *real-time*.

3.2 Hasil Implementasi Sistem

Gambar 11 menunjukkan hasil implementasi sistem pemantauan kondisi meja secara *real-time* menggunakan model YOLOv8m pada lingkungan rumah makan. Sistem mampu mendeteksi setiap meja, mengklasifikasikannya ke dalam tiga kategori, yaitu Meja Kosong, Meja Terisi, dan Meja Kotor, kemudian menampilkan hasil deteksi dalam bentuk *bounding box*, label kelas, dan nilai tingkat kepercayaan (*confidence score*) pada setiap objek yang terdeteksi. Selain itu, sistem juga menghitung jumlah meja pada setiap kategori dan menampilkan informasi tingkat okupansi (*occupancy*) serta status keramaian rumah makan secara otomatis pada dashboard.

Pada Gambar 11(a), seluruh meja berhasil dideteksi dalam kondisi kosong sehingga dashboard menampilkan informasi Meja Terisi: 0, Meja Kosong: 18, dan Meja Kotor: 0. Berdasarkan hasil tersebut, sistem menghitung tingkat okupansi (*occupancy*) sebesar 0% dan mengklasifikasikan kondisi rumah makan sebagai SEPI. Hasil ini menunjukkan bahwa sistem mampu mengenali kondisi ketika tidak terdapat meja yang sedang digunakan oleh pelanggan. Selanjutnya, Gambar 11(b) menunjukkan kondisi rumah makan yang didominasi oleh meja kotor. Sistem mendeteksi 5 meja terisi, 13 meja kotor, dan 0 meja kosong, sehingga tingkat okupansi yang diperoleh sebesar 27,8% dengan status keramaian SEPI. Hasil deteksi menunjukkan bahwa sistem mampu mengidentifikasi kondisi meja pada lingkungan yang terdapat beberapa pelanggan dan objek meja dengan posisi yang berdekatan. Sementara itu, Gambar 11(c) menunjukkan kondisi ketika seluruh meja telah digunakan oleh pelanggan. Sistem mendeteksi 18 meja terisi, tanpa adanya meja kosong maupun meja kotor, sehingga tingkat okupansi mencapai 100% dan status rumah makan berubah menjadi RAMAI/FULL. Perubahan status tersebut dilakukan secara otomatis berdasarkan hasil perhitungan jumlah meja yang terdeteksi dalam kondisi terisi.



Gambar 11. Hasil Implementasi Dashboard Pemantauan Kondisi Meja Secara Real-Time: (a) kondisi meja kosong, (b) kondisi meja sebagian terisi dan kotor, dan (c) kondisi meja penuh

Berdasarkan hasil implementasi tersebut, sistem mampu melakukan pemantauan kondisi meja secara **real-time** dengan menampilkan hasil deteksi, jumlah meja pada setiap kategori, tingkat okupansi, serta status keramaian rumah makan secara otomatis. Informasi yang dihasilkan dapat membantu pengelola rumah makan dalam memantau ketersediaan meja, memperkirakan tingkat kepadatan pengunjung, serta mendukung pengambilan keputusan operasional, seperti mengarahkan pelanggan ke meja yang masih tersedia atau mempercepat proses pembersihan meja yang telah selesai digunakan. Dengan demikian, sistem yang dikembangkan menunjukkan potensi untuk meningkatkan efisiensi pengelolaan rumah makan melalui pemanfaatan teknologi **computer vision** berbasis **YOLOv8**.

3.3 Pengujian Sistem

Pengujian dilakukan untuk memverifikasi kesesuaian fungsi-fungsi pada sistem pemantauan kondisi meja dengan kebutuhan yang telah ditetapkan. Metode *black-box testing* digunakan dengan memusatkan evaluasi pada respons keluaran terhadap masukan tertentu, tanpa meninjau mekanisme internal maupun struktur program. Pengujian meliputi beberapa fungsi utama, yaitu aktivasi kamera, deteksi kondisi meja, klasifikasi meja, perhitungan jumlah meja pada setiap kategori, serta penentuan tingkat keramaian rumah makan. Hasil pengujian fungsionalitas sistem disajikan berdasarkan Tabel 4, seluruh fungsi utama berhasil dijalankan sesuai dengan kebutuhan sistem yang telah dirancang.

Tabel 4. Pengujian Fungsionalitas

Skenario Pengujian	Hasil yang Diharapkan	Hasil
Kamera Aktif	<i>Video streaming</i> tampil	Berhasil
Deteksi Meja	<i>Bounding box</i> muncul	Berhasil
Klasifikasi Meja	Label sesuai kelas	Berhasil
Perhitungan Jumlah Meja	Jumlah sesuai deteksi	Berhasil
Aktivitas Pengunjung pada Rumah Makan	Kategori keramaian tampil	Berhasil

Berdasarkan Tabel 4, sistem berhasil menampilkan *video streaming* dari kamera, mendeteksi objek meja dengan *bounding box*, mengklasifikasikan kondisi meja ke dalam kelas Meja Kosong, Meja Terisi, dan Meja Kotor, serta menghitung jumlah meja pada setiap kategori secara otomatis. Selain itu, sistem juga mampu menampilkan kategori tingkat keramaian rumah makan, yaitu Sepi, Normal, atau Ramai, berdasarkan hasil deteksi kondisi meja. Hasil tersebut menunjukkan bahwa seluruh fungsi yang diimplementasikan telah berjalan dengan baik dan sistem siap digunakan sebagai pendukung pemantauan kondisi meja pada rumah makan secara *real-time*.

3.4 Pembahasan

Dari hasil pelatihan dan evaluasi yang dilakukan, ketiga varian YOLOv8 mampu mendeteksi kondisi meja dengan performa yang baik. YOLOv8m memberikan hasil terbaik pada data uji dengan Precision sebesar 95,82%, Recall 94,95%, mAP@0.5 sebesar 97,95%, dan mAP@0.5:0.95 sebesar 94,22%. Hasil kurva pelatihan menunjukkan penurunan *training loss* dan *validation loss* serta peningkatan metrik evaluasi hingga relatif stabil, sehingga tidak menunjukkan indikasi *overfitting* yang signifikan. Mekanisme *Early Stopping* turut membantu menghentikan pelatihan ketika performa tidak lagi meningkat. Berdasarkan *Confusion Matrix*, model mampu mengklasifikasikan ketiga kelas dengan baik, meskipun masih terdapat kesalahan terutama antara Meja Kosong dan Meja Kotor. Kesalahan tersebut dapat dipengaruhi oleh kemiripan karakteristik visual, variasi pencahayaan, sudut pengambilan gambar, *occlusion*, serta ketidakseimbangan jumlah anotasi antar kelas.

Model YOLOv8m kemudian diimplementasikan pada sistem monitoring untuk melakukan deteksi kondisi meja secara *real-time*. Sistem mampu menampilkan *bounding box* dan label kelas, menghitung jumlah meja pada setiap kategori, serta menampilkan tingkat keramaian rumah makan berdasarkan hasil deteksi. Hasil pengujian menunjukkan bahwa sistem mampu menjalankan fungsi utamanya sesuai kebutuhan. Meskipun memberikan hasil yang baik, penelitian ini masih memiliki keterbatasan pada variasi dataset. Penelitian selanjutnya dapat meningkatkan jumlah dan keragaman data, khususnya dalam hal kondisi pencahayaan, sudut pengambilan gambar, dan kepadatan pengunjung. Sistem juga dapat dikembangkan dengan fitur *object tracking*, integrasi kamera CCTV, dan notifikasi otomatis.

IV. SIMPULAN

Hasil penelitian yang telah dilakukan menunjukkan bahwa algoritma YOLOv8 berhasil diterapkan untuk mendeteksi kondisi meja pada rumah makan berdasarkan tiga kelas, yaitu Meja Kosong, Meja Terisi, dan Meja Kotor. Dalam penelitian ini, tiga varian model YOLOv8 (YOLOv8n, YOLOv8s, dan YOLOv8m) diuji dengan dataset yang diperoleh dari proses perekaman langsung di lingkungan rumah makan. Hasilnya menunjukkan bahwa YOLOv8m menunjukkan performa terbaik dibandingkan dengan dua varian lainnya dengan nilai Precision sebesar 95,82%, Recall sebesar 94,95%, mAP@50 sebesar 97,95%, dan mAP@50-95 sebesar 94,22%. Nilai tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam mendeteksi dan mengklasifikasikan kondisi meja secara akurat pada berbagai kondisi operasional rumah makan.

Model dengan performa terbaik kemudian diimplementasikan ke dalam sistem monitoring untuk mendukung proses deteksi kondisi meja secara *real-time*. Hasil pengujian sistem menunjukkan bahwa seluruh fungsi utama, mulai dari penerimaan *video streaming* menggunakan kamera webcam, proses deteksi objek, klasifikasi kondisi meja, hingga penyajian informasi pada dashboard, dapat berjalan sesuai dengan kebutuhan. Sistem yang dikembangkan mampu

memberikan informasi mengenai jumlah meja kosong, meja terisi, dan meja kotor secara otomatis, sehingga dapat membantu pengelola rumah makan dalam memantau kondisi meja secara lebih cepat, efisien, dan mendukung peningkatan kualitas pelayanan kepada pelanggan.

Variasi dataset yang digunakan adalah salah satu dari beberapa keterbatasan penelitian ini. Oleh karena itu, penelitian selanjutnya disarankan untuk menambah jumlah dataset, memperkaya variasi kondisi lingkungan, seperti perubahan pencahayaan, sudut pengambilan gambar, tingkat kepadatan pengunjung, serta kondisi operasional rumah makan yang lebih beragam. Selain itu, pengembangan sistem dapat dilakukan dengan menambahkan fitur *object tracking*, integrasi dengan kamera CCTV, maupun notifikasi otomatis untuk meningkatkan kemampuan sistem dalam mendukung proses pemantauan kondisi meja secara lebih optimal dan berkelanjutan.

REFERENSI

- [1] M. dan Minuman, "Statistik Penyediaan BADAN PUSAT STATISTIK BPS-STATISTICS INDONESIA," 2023.
- [2] N. Purnomo, W. Gata, M. R. Kusuma, R. M. Dinata, and M. B. Husna, "IMPLEMENTASI YOU ONLY LOOK ONCE v8 DALAM DETEKSI MAKANAN WARUNG TEGAL UNTUK SISTEM PERHITUNGAN HARGA OTOMATIS," 2025.
- [3] M. Faris Afif, R. Eri Werdani, D. Administrasi Bisnis, and U. Diponegoro, "PENGARUH KUALITAS PELAYANAN, KUALITAS PRODUK, HARGA TERHADAP KEPUASAN KONSUMEN," 2022. [Online]. Available: <https://ejournal3.undip.ac.id/index.php/jiab>
- [4] W. Indah Kusumawati, H. Pratikno, and Y. Pradeska Admaja, "Sistem Penghitung Jumlah Pengunjung Restoran Menggunakan Kamera Berbasis Single Shot Detector (SSD)," *Journal of Technology and Informatics (JoTI)*, vol. 3, no. 1, pp. 19–26, Oct. 2021, doi: 10.37802/joti.v3i1.197.
- [5] I. Zamarli, H. Kurniawan, and W. Darwin, "Implementasi Algoritma YOLOv8 untuk Mendeteksi Objek Manusia Secara Real-Time Menggunakan IP Camera di Pekarangan Rumah," *Jurnal Penelitian Nusantara*, vol. 1, pp. 432–441, 2025, doi: 10.59435/menulis.v1i10.706.
- [6] H. Achmad, A. Pramudwiatmoko, M. Satrio Gumilang, B. Al Karim, and H. Wiyono, "Analisis Kinerja Model Deteksi Objek Yolo, Ssd, dan Faster R-Cnn pada Citra Penglihatan Malam untuk Pengenalan Tindak Kejahatan," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 12, no. 1, pp. 145–152, Feb. 2025, doi: 10.25126/jtiik.2025128409.
- [7] D. S. Ariansyah and D. S. Ariansyah, "PENDETEKSI KATA DALAM BAHASA ISYARAT MENGGUNAKAN ALGORITMA YOLO VERSI 8," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, Aug. 2024, doi: 10.23960/jitet.v12i3.4904.
- [8] I. Topan Adib Amrulloh *et al.*, "EVALUASI AUGMENTASI DATA PADA DETEKSI PENYAKIT DAUN TEBU DENGAN YOLOV8," 2024.
- [9] Z. Li, Y. Zhu, S. Sui, Y. Zhao, P. Liu, and X. Li, "Real-time detection and counting of wheat ears based on improved YOLOv7," *Comput. Electron. Agric.*, vol. 218, Mar. 2024, doi: 10.1016/j.compag.2024.108670.
- [10] A. Hidayah, S. Zuhriyah, B. E. W. Asrul, Yuyun, and E. Prakasa, "Integration of YOLOv5 Algorithm and OpenCV in Innovative Smart Parking Management Approach," *Jurnal RESTI*, vol. 8, no. 3, pp. 413–422, Jun. 2024, doi: 10.29207/resti.v8i3.5728.
- [11] A. Kerem Güler and A. Musa, "Real-Time Table Occupancy Detection in Restaurants Using Object Detection and Computer Vision Techniques," *Journal of Artificial Intelligence and Data Science (JAIDA)*, vol. 5, no. 1, pp. 12–27, 2025, [Online]. Available: <https://dergipark.org.tr/pub/jaida>
- [12] A. R. Amanullah, D. Rudhistiar, and N. Vendyansyah, "IMPLEMENTASI SISTEM DETEKSI PELANGGAN DAN MAKANAN MENGGUNAKAN METODE YOLO PADA RESTORAN BERSAMA JAYA," 2025.
- [13] F. M. Talaat and H. ZainEldin, "An improved fire detection approach based on YOLO-v8 for smart cities," *Neural Comput. Appl.*, vol. 35, no. 28, pp. 20939–20954, Oct. 2023, doi: 10.1007/s00521-023-08809-1.
- [14] M. A. Fahrezi and E. P. Widiyanto, "Implementasi YOLOv8 Dalam Penghitung Masuk Dan Keluar Manusia Pada Gedung," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 11, no. 3, 2024, [Online]. Available: <http://jurnal.mdp.ac.id>
- [15] L. Susanti, N. K. Daulay, and B. Intan, "Sistem Absensi Mahasiswa Berbasis Pengenalan Wajah Menggunakan Algoritma YOLOv5," *JURIKOM (Jurnal Riset Komputer)*, vol. 10, no. 2, p. 640, Apr. 2023, doi: 10.30865/jurikom.v10i2.6032.

- [16] D. G. Manurung *et al.*, “Deteksi Dan Klasifikasi Hama Potato Beetle Pada Tanaman Kentang Menggunakan YOLOV8,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 4, pp. 723–734, Aug. 2024, doi: 10.25126/jtiik.1148092.
- [17] N. Sujana, M. Malik Mutoffar, and A. Azzam Haryanto, “ANALISIS KINERJA YOLOV8 OPTIMALISASI ROBOFLOW UNTUK DETEKSI EKSPRESI WAJAH EMOSIONAL DENGAN MACHINE LEARNING,” vol. 06, 2024.
- [18] L. Suroiyah, Y. Rahmawati, and R. Dijaya, “FACE MASK DETECTION USING YOLO V5,” *Jurnal Teknik Informatika (Jutif)*, vol. 4, no. 6, pp. 1277–1286, Dec. 2023, doi: 10.52436/1.jutif.2023.4.6.1043.
- [19] B. Ma *et al.*, “Using an improved lightweight YOLOv8 model for real-time detection of multi-stage apple fruit in complex orchard environments,” *Artificial Intelligence in Agriculture*, vol. 11, pp. 70–82, Mar. 2024, doi: 10.1016/j.aiia.2024.02.001.
- [20] D. Nimma *et al.*, “Object detection in real-time video surveillance using attention based transformer-YOLOv8 model,” *Alexandria Engineering Journal*, vol. 118, pp. 482–495, Apr. 2025, doi: 10.1016/j.aej.2025.01.032.
- [21] N. Akbar and A. Rahman, “Pengaruh Image Size pada Penghitung Jumlah Orang Dalam Ruangan Menggunakan Metode YOLOv8,” *Jurnal Algoritme*, vol. 5, no. 2, pp. 176–187, Apr. 2025, doi: 10.35957/algoritme.v5i2.9035.

Conflict of Interest Statement:

The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.