

Pengembangan Sistem Pembelajaran Berbasis Deep Learning untuk Interpretasi Display Perangkat Medis

Khamdan Annas Fakhryza^{*1}, Eko Nugroho², Setyo Adi Nugroho³, Efa Yumna Purwono⁴

^{1,2,3}Program Studi Teknik Elektromedis, Fakultas Sains & Teknologi, Universitas Muhammadiyah PKU, Surakarta, Indonesia

⁴Program Studi Teknik Elektro, Fakultas Teknologi Industri, Universitas Islam Sultan Agung, Semarang, Indonesia

Email: ¹khamdan@umpku.ac.id, ²ekonugroho@umpku.ac.id, ³setyoadinugroho@umpku.ac.id, ⁴efayumna@gmail.com

Abstrak

Pembacaan manual nilai numerik pada display perangkat medis masih berpotensi menimbulkan kesalahan yang dapat berdampak pada keselamatan pasien dan kualitas layanan kesehatan. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem otomatis berbasis deep learning yang mampu mengenali dan menginterpretasikan digit secara akurat, serta dapat dimanfaatkan sebagai media pembelajaran interaktif. Metode yang digunakan adalah model deteksi objek YOLOv8 yang dilatih pada dataset sebanyak 1.771 citra dengan 13 kelas. Hasil evaluasi menunjukkan bahwa model mencapai precision sebesar 0,881, recall sebesar 0,836, mAP50 sebesar 0,878, dan mAP50-95 sebesar 0,673. Hasil tersebut menunjukkan bahwa model yang diusulkan memiliki kinerja deteksi yang akurat dan andal dalam berbagai kondisi citra. Sistem kemudian diimplementasikan dalam aplikasi berbasis web yang memungkinkan deteksi digit secara real-time. Secara keseluruhan, penelitian ini menegaskan bahwa integrasi deep learning dengan sistem interaktif tidak hanya meningkatkan akurasi interpretasi display perangkat medis, tetapi juga mendukung efektivitas pembelajaran berbasis teknologi secara aplikatif.

Kata kunci: *Computer Vision, Deep Learning, Media Pembelajaran, Perangkat Medis, Real-Time, YOLOv8.*

Development of a Deep Learning-Based Learning System for Interpreting Medical Device Displays

Abstract

Manual reading of numerical values on medical device displays still poses a risk of error, which may affect patient safety and the quality of healthcare services. Therefore, this study aims to develop an automated system based on deep learning that is capable of accurately recognizing and interpreting digits, while also serving as an interactive learning medium. The proposed method employs the YOLOv8 object detection model trained on a dataset consisting of 1,771 images with 13 classes. The evaluation results demonstrate that the model achieves a precision of 0.881, recall of 0.836, mAP50 of 0.878, and mAP50-95 of 0.673. These results indicate that the proposed model is capable of providing reliable and accurate digit detection performance under various conditions. The system is implemented as a web-based application that enables real-time digit detection. Overall, this study confirms that integrating deep learning with an interactive system can improve both the accuracy of medical display interpretation and the effectiveness of technology-based learning.

Keywords: *Computer Vision, Deep Learning, Learning Media, Medical Device, Real-Time, YOLOv8.*

1. PENDAHULUAN

Perkembangan teknologi *artificial intelligence*, khususnya pada bidang *computer vision*, telah memberikan kontribusi signifikan dalam berbagai sektor, termasuk kesehatan dan pendidikan [1], [2]. Pemanfaatan *deep learning* dalam mendeteksi dan mengenali objek secara otomatis memungkinkan peningkatan efisiensi serta akurasi dalam interpretasi data visual. Dalam konteks perangkat medis, pembacaan nilai numerik pada *display* alat masih banyak dilakukan secara manual, sehingga berpotensi menimbulkan kesalahan interpretasi yang dapat berdampak pada kualitas pelayanan dan keselamatan [3]–[5].

Di sisi lain, dalam proses pembelajaran pada bidang teknik dan kesehatan, mahasiswa sering mengalami kesulitan dalam memahami cara kerja serta interpretasi tampilan perangkat medis secara langsung. Keterbatasan alat praktik dan kurangnya media pembelajaran berbasis teknologi menyebabkan proses pembelajaran menjadi kurang optimal, terutama dalam aspek visualisasi dan pemahaman aplikatif [6], [7]. Kondisi ini menunjukkan perlunya pengembangan media pembelajaran yang interaktif, adaptif, dan berbasis teknologi terkini [3], [5].

Berbagai penelitian telah mengembangkan metode deteksi objek menggunakan *deep learning*, khususnya model YOLO (*You Only Look Once*), yang memiliki performa tinggi dalam hal kecepatan dan akurasi [8], [9]. Model-model terbaru seperti YOLOv8 juga menunjukkan peningkatan performa dalam deteksi objek secara *real-time* [10]. Namun, sebagian besar penelitian tersebut masih berfokus pada aspek teknis deteksi tanpa mengintegrasikan hasilnya ke dalam sistem pembelajaran yang dapat digunakan secara langsung oleh pengguna [11], [12]. Selain itu, implementasi *computer vision* untuk interpretasi *display* perangkat medis secara end-to-end yang terintegrasi dengan media pembelajaran interaktif masih sangat terbatas.

Berdasarkan permasalahan tersebut, penelitian ini mengembangkan sistem berbasis *deep learning* menggunakan model YOLOv8 untuk mengenali digit pada *display* perangkat medis yang diintegrasikan dalam aplikasi berbasis web. Sistem ini dirancang tidak hanya sebagai alat deteksi, tetapi juga sebagai media pembelajaran interaktif yang memungkinkan pengguna melakukan eksplorasi melalui proses unggah citra dan memperoleh hasil secara *real-time* [4], [13]. Keunggulan sistem yang dikembangkan terletak pada integrasi antara model deteksi berbasis *deep learning* dengan antarmuka interaktif berbasis web, sehingga tidak hanya berfungsi sebagai alat analisis, tetapi juga sebagai sarana pembelajaran berbasis eksperimen langsung (*hands-on learning*). Dengan demikian, penelitian ini memberikan kontribusi dalam pengembangan media pembelajaran berbasis kecerdasan buatan serta mendukung peningkatan pemahaman pengguna terhadap penerapan *computer vision* dalam bidang medis [14].

Meskipun berbagai penelitian telah mengembangkan metode deteksi objek berbasis *deep learning*, sebagian besar penelitian masih berfokus pada aspek teknis deteksi tanpa mengintegrasikan hasilnya ke dalam sistem pembelajaran yang dapat digunakan secara langsung oleh pengguna. Selain itu, implementasi sistem interpretasi *display* perangkat medis secara end-to-end yang terintegrasi dengan media pembelajaran interaktif masih sangat terbatas. Oleh karena itu, penelitian ini menawarkan kontribusi berupa pengembangan sistem berbasis YOLOv8 yang tidak hanya mampu mendeteksi digit secara akurat, tetapi juga mengintegrasikannya dalam platform pembelajaran interaktif berbasis web. Pendekatan ini diharapkan dapat meningkatkan pemahaman pengguna melalui metode pembelajaran berbasis eksperimen secara langsung.

2. METODE PENELITIAN

Penelitian ini bertujuan untuk mengembangkan sistem pembelajaran berbasis *deep learning* dalam mengenali dan menginterpretasikan digit pada *display* perangkat medis. Permasalahan utama yang diformulasikan adalah bagaimana merancang model deteksi objek yang mampu mengidentifikasi digit secara akurat pada citra *display*, serta mengintegrasikan hasil deteksi tersebut ke dalam sistem berbasis web yang dapat digunakan sebagai media pembelajaran interaktif.

2.1 Dataset dan Pra-pemrosesan

Dataset yang digunakan dalam penelitian ini terdiri dari 1.771 citra *display* perangkat medis dengan total 13 kelas, yaitu digit angka (0–9), simbol titik (*.*), serta area layar (*screen*). Dataset dibagi menjadi data latih dan validasi dengan proporsi *approximately* 80:20 untuk memastikan kemampuan generalisasi model terhadap data baru.

Distribusi data pada Tabel 1 menunjukkan jumlah *instance objek* (bounding box) pada masing-masing kelas, bukan jumlah citra. Hal ini dikarenakan dalam satu citra dapat terdapat lebih dari satu objek digit yang terdeteksi.

Tabel 1. Distribusi Instance Objek pada Dataset

Kelas	Train (Instance)	Valid (Instance)	Total
-	21	0	21
.	444	22	466
0	720	59	779
1	468	44	512
2	396	32	428
3	282	19	301
4	279	23	302
5	339	22	361

6	345	16	361
7	249	22	271
8	291	14	305
9	245	23	268
screen	270	26	296
Total	4,349	322	4,671

Setiap citra dianotasi menggunakan bounding box dengan format YOLO yang direpresentasikan sebagai (x_c, y_c, w, h) , di mana x_c dan y_c merupakan koordinat pusat objek, sedangkan w dan h adalah lebar dan tinggi objek yang telah dinormalisasi terhadap dimensi citra.

Tahap pra-pemrosesan dilakukan dengan mengubah ukuran citra menjadi 640×640 piksel untuk menyesuaikan dengan konfigurasi model YOLOv8. Selain itu, diterapkan teknik augmentasi data seperti *horizontal flipping*, *scaling*, dan penyesuaian intensitas warna guna meningkatkan keragaman data latih serta mengurangi risiko overfitting.

2.2 Arsitektur Model YOLOv8

Model yang digunakan dalam penelitian ini adalah YOLOv8, yaitu model deteksi objek berbasis convolutional neural network (CNN) yang dirancang untuk mendukung deteksi objek secara real-time dengan tingkat akurasi yang tinggi. Arsitektur YOLOv8 terdiri dari tiga komponen utama, yaitu backbone, neck, dan head, yang bekerja secara terintegrasi dalam mengekstraksi dan memproses informasi visual dari citra input [15].

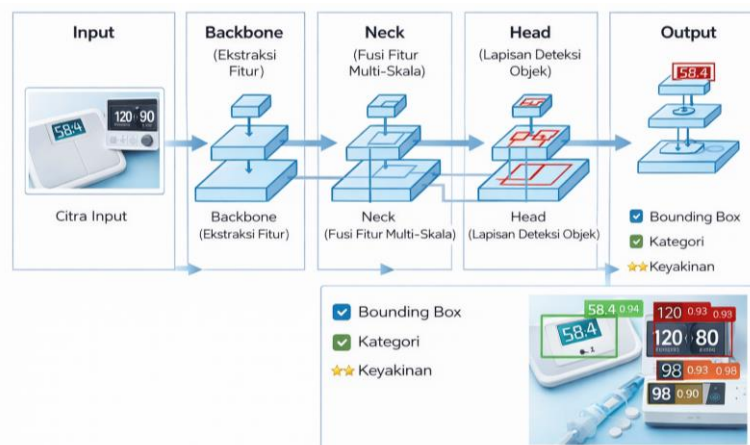
Komponen backbone berperan dalam mengekstraksi fitur penting dari citra input melalui proses konvolusi bertingkat, sehingga menghasilkan representasi fitur yang kaya dan informatif. Selanjutnya, neck berfungsi untuk menggabungkan fitur dari berbagai skala menggunakan mekanisme feature fusion, sehingga model mampu mendeteksi objek dengan ukuran yang beragam. Pada tahap akhir, head menghasilkan prediksi berupa kelas objek serta koordinat bounding box yang merepresentasikan lokasi objek pada citra [16].

Fungsi objektif yang digunakan dalam proses pelatihan model dirumuskan sebagai berikut:

$$L = L_{box} + L_{cls} + L_{dfl} \quad (1)$$

Di mana L_{box} merepresentasikan kesalahan regresi lokasi objek, L_{cls} menunjukkan kesalahan klasifikasi, dan L_{dfl} (*distribution focal loss*) digunakan untuk meningkatkan akurasi dalam regresi bounding box. Kombinasi ketiga komponen loss tersebut memungkinkan model untuk mencapai keseimbangan antara akurasi deteksi dan ketepatan lokalisasi objek.

Ilustrasi arsitektur model YOLOv8 yang terdiri dari *backbone*, *neck*, dan *head* ditunjukkan pada Gambar 1.



Gambar 1. Arsitektur model YOLOv8 yang terdiri dari backbone, neck, dan head

2.3 Proses Pelatihan Model

Pelatihan model dilakukan dengan menggunakan beberapa parameter utama, yaitu jumlah *epoch* sebanyak 30, ukuran citra sebesar 640×640 piksel, *optimizer* AdamW, serta *batch size* sebesar 16. Pemilihan parameter ini

didasarkan pada kebutuhan untuk mencapai keseimbangan antara akurasi model dan efisiensi komputasi selama proses pelatihan [17], [18].

Pelatihan model dilakukan dengan jumlah epoch sebanyak 30 dan ukuran citra 640×640 piksel, yang dipilih untuk mencapai keseimbangan antara akurasi deteksi dan efisiensi komputasi. Resolusi ini umum digunakan dalam model YOLOv8 untuk mempertahankan detail objek tanpa meningkatkan beban komputasi secara signifikan.

Proses optimasi dilakukan menggunakan metode *gradient descent* untuk meminimalkan fungsi *loss* yang telah dirumuskan. Selama pelatihan berlangsung, performa model dievaluasi secara berkala menggunakan data validasi guna memantau perkembangan kinerja model serta mencegah terjadinya *overfitting*. Pendekatan ini memungkinkan model untuk mempertahankan kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya.

2.4 Evaluasi Model

Kinerja model dievaluasi menggunakan beberapa metrik utama, yaitu *precision*, *recall*, dan *mean Average Precision* (mAP), yang umum digunakan dalam tugas deteksi objek untuk menilai akurasi dan kelengkapan hasil prediksi.

Nilai *precision* mengukur tingkat ketepatan model dalam menghasilkan prediksi positif yang benar, yang dirumuskan sebagai:

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2)$$

Sementara itu, *recall* digunakan untuk mengukur kemampuan model dalam mendeteksi seluruh objek yang sebenarnya ada dalam citra, yang dirumuskan sebagai:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (3)$$

Nilai mAP dihitung sebagai rata-rata *Average Precision* (AP) pada berbagai nilai *Intersection over Union* (IoU), sehingga memberikan gambaran menyeluruh mengenai performa model dalam mendeteksi objek dengan tingkat akurasi dan ketepatan lokalisasi yang berbeda-beda. Dengan demikian, kombinasi metrik *precision*, *recall*, dan mAP memungkinkan evaluasi model dilakukan secara komprehensif, baik dari sisi ketepatan deteksi maupun kemampuan menemukan seluruh objek yang relevan [19].

2.5 Arsitektur Sistem

Sistem yang dikembangkan dalam penelitian ini merupakan integrasi antara model deteksi objek berbasis YOLOv8 dan mekanisme rekonstruksi nilai numerik secara otomatis. Sistem dirancang untuk mampu melakukan interpretasi nilai numerik dari citra display perangkat medis secara *end-to-end*, mulai dari proses input hingga menghasilkan output berupa nilai akhir [2].

Alur kerja sistem diawali dengan proses input citra melalui antarmuka berbasis web, yang memungkinkan pengguna mengunggah citra display perangkat medis secara langsung. Selanjutnya, citra diproses menggunakan model YOLOv8 untuk mendeteksi objek berupa digit dan elemen terkait lainnya. Hasil deteksi kemudian disaring untuk mengambil hanya kelas digit (0–9) yang relevan dengan proses interpretasi nilai.

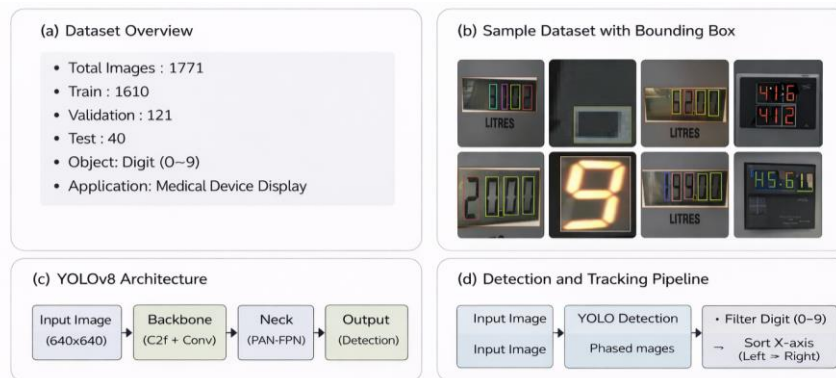
Tahap berikutnya adalah pengurutan digit berdasarkan posisi koordinat horizontal (sumbu x), yang merepresentasikan urutan pembacaan nilai dari kiri ke kanan. Setelah itu, digit yang telah terurut digabungkan untuk membentuk nilai numerik akhir melalui proses rekonstruksi.

Proses rekonstruksi nilai numerik dirumuskan sebagai berikut:

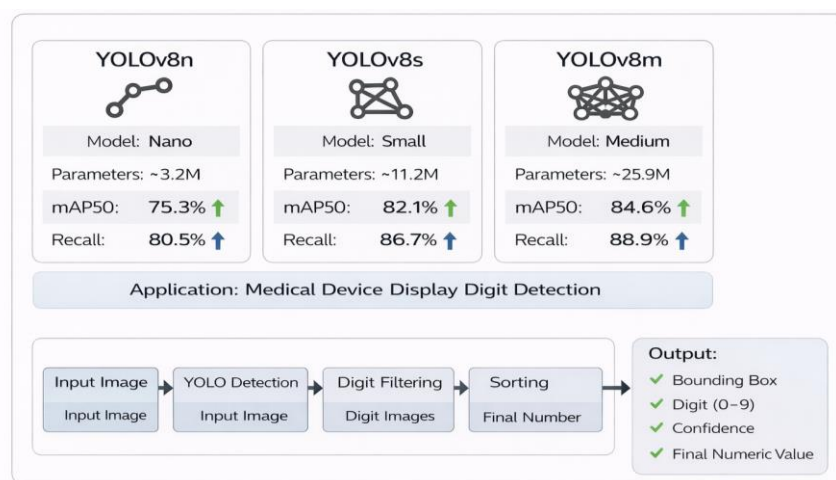
$$N = \sum_{i=1}^k d_i \times 10^{k-i} \quad (4)$$

Di mana d_i merupakan digit hasil deteksi dan k adalah jumlah digit yang terdeteksi. Pendekatan ini memungkinkan sistem untuk mengubah hasil deteksi objek menjadi representasi nilai numerik yang utuh dan bermakna.

Secara keseluruhan, integrasi antara deteksi objek dan mekanisme rekonstruksi ini memungkinkan sistem untuk melakukan interpretasi nilai secara otomatis dan real-time, sehingga dapat digunakan tidak hanya sebagai alat analisis, tetapi juga sebagai media pembelajaran interaktif berbasis teknologi *computer vision* [20], [21].



Gambar 2. Gambaran umum sistem yang diusulkan: (a) distribusi dataset, (b) contoh citra dengan anotasi bounding box, (c) arsitektur model YOLOv8, dan (d) pipeline deteksi serta rekonstruksi nilai numerik



Gambar 3. Pipeline sistem deteksi dan rekonstruksi nilai numerik berbasis YOLOv8

Pendekatan ini menunjukkan bahwa sistem tidak hanya melakukan deteksi objek, tetapi juga mampu melakukan interpretasi semantik terhadap informasi visual yang ditampilkan pada perangkat medis.

2.6 Implementasi Sistem

Sistem yang dikembangkan diimplementasikan dalam bentuk aplikasi berbasis web menggunakan platform Streamlit, sehingga dapat diakses secara mudah dan interaktif oleh pengguna. Melalui antarmuka yang disediakan, pengguna dapat mengunggah citra display perangkat medis, yang selanjutnya diproses oleh model yang telah dilatih untuk melakukan deteksi digit secara otomatis. Hasil deteksi kemudian ditampilkan secara real-time, lengkap dengan informasi berupa *bounding box*, kelas digit, serta nilai numerik hasil rekonstruksi.

Implementasi ini tidak hanya berfokus pada aspek fungsional sebagai alat deteksi, tetapi juga dirancang sebagai media pembelajaran interaktif. Pengguna dapat memahami proses deteksi objek dan interpretasi numerik secara langsung melalui interaksi dengan sistem, sehingga mendukung pendekatan pembelajaran berbasis eksperimen (*hands-on learning*). Dengan demikian, sistem yang dikembangkan memberikan nilai tambah tidak hanya dari sisi teknis, tetapi juga dalam mendukung proses pembelajaran berbasis teknologi *computer vision*.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pengujian model deteksi berbasis YOLOv8 serta analisis performa sistem dalam mengenali digit pada display perangkat medis. Evaluasi dilakukan menggunakan metrik *precision*, *recall*, *mean Average Precision* (mAP), serta analisis kesalahan (*error analysis*) untuk memperoleh pemahaman komprehensif terhadap kinerja model.

3.1 Hasil Evaluasi Model

Hasil evaluasi model pada dataset validasi menunjukkan bahwa model memiliki performa yang baik dalam mendeteksi digit pada display perangkat medis. Ringkasan performa model disajikan pada Tabel 2, sedangkan dinamika proses pelatihan ditunjukkan pada Gambar 4.


Metrik	Nilai
Precision	0.881
Recall	0.836
mAP50	0.878
mAP50-95	0.673

Berdasarkan Tabel 2, model mencapai nilai *precision* sebesar 0,881 yang menunjukkan bahwa sebagian besar prediksi yang dihasilkan merupakan deteksi yang benar. Hal ini mengindikasikan tingkat akurasi yang tinggi dalam mengidentifikasi objek yang relevan pada citra.

Di sisi lain, nilai *recall* sebesar 0,836 menunjukkan bahwa model mampu mendeteksi sebagian besar objek yang terdapat dalam citra, meskipun masih terdapat sejumlah objek yang tidak terdeteksi (*false negative*). Dalam konteks perangkat medis yang bersifat *safety-critical*, nilai *recall* menjadi parameter yang sangat penting karena kegagalan dalam mendeteksi objek dapat berpotensi menyebabkan kesalahan dalam interpretasi nilai yang ditampilkan.

Nilai mAP50 sebesar 0,878 menunjukkan bahwa model memiliki kemampuan deteksi yang sangat baik pada ambang *Intersection over Union* (IoU) sebesar 0,5. Sementara itu, nilai mAP50-95 sebesar 0,673 mengindikasikan bahwa performa model tetap stabil pada rentang evaluasi yang lebih ketat, meskipun mengalami penurunan akibat sensitivitas terhadap variasi ukuran dan posisi *bounding box*.

Selain itu, Gambar 4 menunjukkan bahwa selama proses pelatihan, nilai *precision*, *recall*, dan mAP mengalami peningkatan yang konsisten seiring bertambahnya epoch, sementara nilai *loss* pada data pelatihan dan validasi menunjukkan tren penurunan yang stabil. Pola ini mengindikasikan bahwa model berhasil mempelajari fitur dengan baik tanpa mengalami indikasi *overfitting* yang signifikan.



Gambar 4. Kurva performa pelatihan model meliputi precision, recall, mAP, serta nilai loss

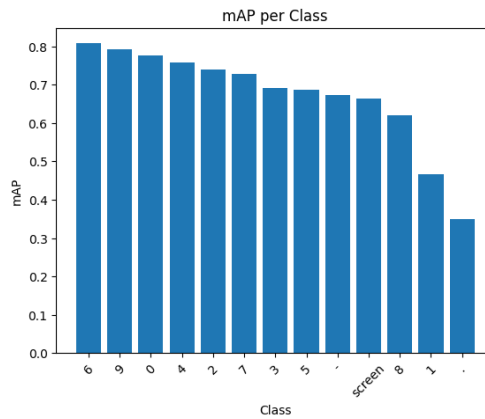
3.2 Analisis Performa per Kelas

Analisis performa per kelas dilakukan untuk mengevaluasi kemampuan model dalam mendeteksi masing-masing digit secara spesifik. Hasil analisis menunjukkan bahwa beberapa kelas digit, seperti “6”, “9”, dan “0”, memiliki nilai *mean Average Precision* (mAP) yang relatif tinggi dibandingkan kelas lainnya, yang mengindikasikan bahwa model mampu mengenali pola visual pada digit-digit tersebut dengan baik.

Sebaliknya, beberapa kelas dengan performa lebih rendah, seperti simbol titik (.) dan digit tertentu, menunjukkan nilai mAP yang lebih rendah. Kondisi ini dipengaruhi oleh beberapa faktor utama, yaitu ketidakseimbangan jumlah data antar kelas serta kemiripan pola visual antar digit. Digit dengan bentuk yang mirip atau kompleks cenderung lebih sulit dibedakan oleh model, terutama ketika jumlah data latih pada kelas tersebut terbatas.

Selain itu, keberadaan kelas “screen” sebagai objek non-digit turut meningkatkan kompleksitas proses klasifikasi, karena model harus mampu membedakan antara area layar dan digit secara simultan. Hal ini menuntut kemampuan ekstraksi fitur yang lebih robust agar tidak terjadi kesalahan klasifikasi.

Gambar 5 menunjukkan distribusi nilai mAP untuk setiap kelas, yang memperlihatkan variasi performa model antar kelas secara lebih rinci.



Gambar 5. Performa deteksi model berdasarkan nilai mAP pada setiap kelas

Secara keseluruhan, hasil ini menunjukkan bahwa distribusi dan kualitas dataset memiliki pengaruh yang signifikan terhadap performa model. Oleh karena itu, peningkatan jumlah data pada kelas yang kurang representatif serta perbaikan keseimbangan dataset menjadi langkah penting dalam pengembangan sistem selanjutnya.

3.3 Analisis Confusion Matrix

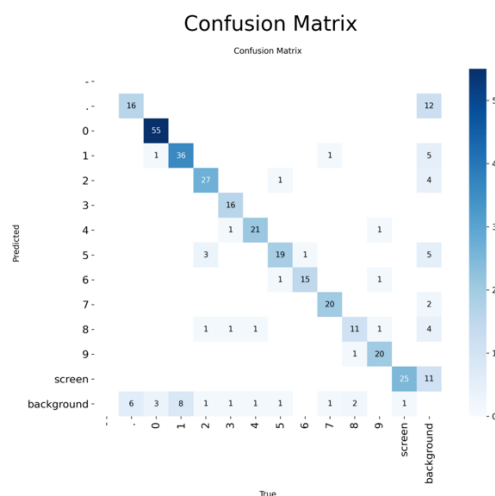
Confusion matrix digunakan untuk menganalisis distribusi kesalahan klasifikasi yang dihasilkan oleh model pada dataset validasi. Berdasarkan Gambar 5, mayoritas prediksi berada pada diagonal utama, yang menunjukkan bahwa model memiliki tingkat klasifikasi yang baik dan mampu mengenali sebagian besar kelas dengan benar.

Meskipun demikian, masih terdapat beberapa kesalahan klasifikasi yang terjadi antar digit dengan kemiripan bentuk visual. Kesalahan yang paling umum terjadi antara digit “1” dan “7”, serta antara digit “5” dan “6”. Hal ini menunjukkan bahwa model mengalami kesulitan dalam membedakan pola visual yang memiliki karakteristik serupa, terutama pada kondisi tertentu.

Kesalahan klasifikasi tersebut umumnya dipengaruhi oleh kualitas citra input, seperti pencahayaan yang tidak merata, adanya noise, serta sudut pengambilan gambar yang kurang optimal. Faktor-faktor ini dapat menyebabkan fitur visual yang diekstraksi menjadi kurang representatif, sehingga meningkatkan kemungkinan terjadinya misclassification.

Selain itu, keberadaan kelas non-digit seperti “screen” dan “background” juga berkontribusi terhadap kompleksitas proses klasifikasi, karena model harus mampu membedakan antara area tampilan dan digit secara bersamaan.

Gambar 6 menyajikan confusion matrix yang menggambarkan distribusi prediksi model terhadap kelas sebenarnya secara lebih rinci.



Gambar 6. Confusion matrix hasil klasifikasi model pada dataset validasi.

Secara keseluruhan, hasil ini menunjukkan bahwa performa model tidak hanya dipengaruhi oleh arsitektur yang digunakan, tetapi juga sangat bergantung pada kualitas dan keragaman data input. Oleh karena itu, peningkatan kualitas citra serta strategi augmentasi yang lebih adaptif menjadi penting untuk mengurangi kesalahan klasifikasi pada penelitian selanjutnya.

3.4 Analisis Kesalahan (Error Analysis)

Analisis kesalahan dilakukan untuk mengidentifikasi jenis kesalahan yang terjadi selama proses deteksi. Hasil analisis ditunjukkan pada Tabel 3.

Tabel 3. Analisis Kesalahan

Jenis Error	Nilai
False Positive	0.118
False Negative	0.164

Berdasarkan Tabel 3, nilai *false negative* sebesar 0,164 lebih tinggi dibandingkan *false positive* sebesar 0,118. Hal ini menunjukkan bahwa model lebih sering gagal mendeteksi objek yang sebenarnya ada dibandingkan menghasilkan deteksi yang salah. Dengan kata lain, masih terdapat sejumlah digit yang tidak terdeteksi oleh sistem.

Dalam konteks perangkat medis yang bersifat *safety-critical*, kondisi ini menjadi perhatian penting karena kegagalan mendeteksi digit dapat menyebabkan informasi yang ditampilkan menjadi tidak lengkap atau terinterpretasi secara keliru. Oleh karena itu, peningkatan nilai *recall* menjadi prioritas utama dalam pengembangan sistem selanjutnya, guna meminimalkan kemungkinan kehilangan informasi penting.

Pendekatan yang digunakan dalam penelitian ini menitikberatkan pada pengurangan *false negative* dibandingkan sekadar menyeimbangkan antara *false positive* dan *false negative*. Strategi ini dipilih untuk meningkatkan aspek keamanan sistem, terutama dalam aplikasi medis yang membutuhkan tingkat keandalan deteksi yang tinggi.

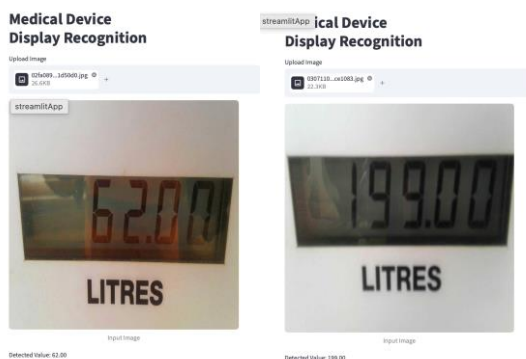
3.5 Hasil Implementasi Sistem

Sistem yang dikembangkan dalam penelitian ini telah berhasil diimplementasikan dalam bentuk aplikasi berbasis web interaktif menggunakan platform Streamlit. Aplikasi tersebut dapat diakses secara daring melalui tautan berikut: <https://digit-medical-display-recognition-6du8p83bezcdblrmn7m6es.streamlit.app/>

Melalui antarmuka yang disediakan, pengguna dapat mengunggah citra display perangkat medis, yang selanjutnya diproses oleh model untuk mendeteksi digit secara otomatis. Hasil deteksi ditampilkan secara real-time, sehingga menunjukkan bahwa model yang diusulkan tidak hanya berfungsi pada tahap eksperimen, tetapi juga memiliki kemampuan untuk diaplikasikan secara langsung dalam lingkungan nyata.

Berdasarkan Gambar 7, sistem mampu mendeteksi digit, mengurutkannya berdasarkan posisi horizontal (sumbu x), serta merekonstruksi nilai numerik secara otomatis. Sebagai contoh, sistem berhasil mengenali nilai “62.00” dan “199.00” dari citra input dengan urutan digit yang tepat. Hal ini menunjukkan bahwa integrasi antara proses deteksi objek dan rekonstruksi numerik berjalan secara efektif dan konsisten.

Gambar 6 menyajikan contoh hasil deteksi digit beserta proses rekonstruksi nilai numerik yang dihasilkan oleh sistem.



Gambar 7. Contoh hasil deteksi digit dan rekonstruksi nilai numerik pada sistem.

Selain sebagai alat deteksi, sistem ini juga dirancang sebagai media pembelajaran interaktif. Pengguna dapat memahami proses kerja *computer vision* dan *deep learning* secara langsung melalui interaksi berbasis citra (*hands-on learning*). Dengan demikian, sistem yang dikembangkan tidak hanya memberikan kontribusi teknis, tetapi juga mendukung pengembangan pembelajaran berbasis teknologi yang lebih aplikatif dan kontekstual.

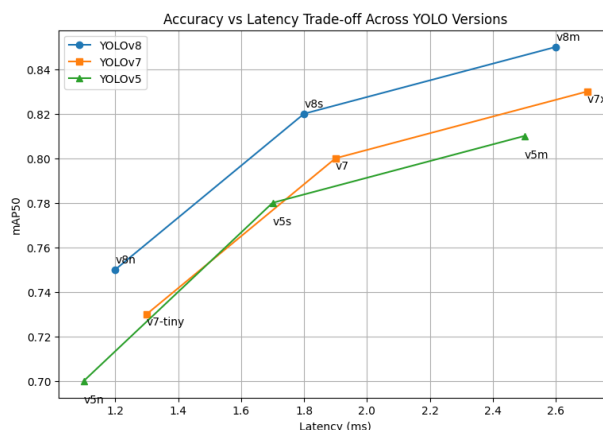
3.6 Pembahasan

Hasil penelitian menunjukkan bahwa model YOLOv8 memiliki performa yang unggul dalam mendeteksi digit pada display perangkat medis, terutama ditinjau dari nilai precision dan mean Average Precision (mAP) yang tinggi. Hal ini sejalan dengan karakteristik YOLOv8 yang dirancang untuk memberikan keseimbangan antara akurasi dan kecepatan, sehingga efektif digunakan dalam skenario deteksi objek secara real-time.

Meskipun demikian, nilai recall yang masih lebih rendah dibandingkan precision menunjukkan adanya keterbatasan model dalam mendeteksi seluruh objek yang terdapat pada citra. Kondisi ini mengindikasikan bahwa masih terdapat objek yang tidak terdeteksi (*false negative*), yang umumnya dipengaruhi oleh ketidakseimbangan distribusi data serta variasi kualitas citra, seperti pencahayaan dan noise.

Dibandingkan dengan model YOLOv5 dan YOLOv7, YOLOv8 menunjukkan peningkatan performa pada nilai mAP dengan tetap mempertahankan latency yang rendah. Perbandingan tersebut ditunjukkan pada Gambar 8, yang mengindikasikan bahwa YOLOv8 lebih optimal untuk diimplementasikan dalam sistem yang membutuhkan respons cepat tanpa mengorbankan akurasi.

Gambar 8 menyajikan perbandingan performa antara model YOLOv5, YOLOv7, dan YOLOv8 berdasarkan nilai mAP dan latency.



Gambar 8. Perbandingan performa model YOLOv5, YOLOv7, dan YOLOv8 berdasarkan mAP dan latency

Lebih lanjut, kontribusi utama penelitian ini tidak hanya terletak pada aspek teknis deteksi objek, tetapi juga pada integrasi sistem sebagai media pembelajaran berbasis kecerdasan buatan. Sistem yang dikembangkan memungkinkan pengguna untuk memahami proses deteksi dan interpretasi numerik secara langsung melalui interaksi berbasis citra, sehingga mendukung pendekatan pembelajaran berbasis praktik (*experiential learning*).

Dengan demikian, penelitian ini memberikan kontribusi yang signifikan pada bidang pendidikan dan teknologi, khususnya dalam pengembangan media pembelajaran interaktif berbasis *deep learning* untuk aplikasi medis. Integrasi antara model deteksi dan sistem pembelajaran ini menjadi nilai tambah yang membedakan penelitian ini dari studi sebelumnya yang umumnya hanya berfokus pada aspek teknis deteksi objek

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem berbasis *deep learning* menggunakan model YOLOv8 untuk mendeteksi dan menginterpretasikan digit pada display perangkat medis secara otomatis. Hasil evaluasi menunjukkan bahwa model memiliki performa yang baik dengan nilai *precision* sebesar 0,881, *recall* sebesar 0,836, serta mAP50 sebesar 0,878, yang mengindikasikan bahwa sistem mampu mencapai tingkat akurasi yang tinggi dan stabil pada berbagai kondisi citra.

Meskipun demikian, perbedaan antara nilai *precision* dan *recall* menunjukkan bahwa model masih memiliki keterbatasan dalam mendeteksi seluruh objek, terutama pada kondisi data yang tidak seimbang dan kualitas citra yang bervariasi. Analisis lebih lanjut mengindikasikan bahwa kemiripan bentuk antar digit serta distribusi dataset yang tidak merata berkontribusi terhadap meningkatnya *false negative*. Dalam konteks perangkat medis yang

bersifat *safety-critical*, kondisi ini menjadi perhatian penting karena berpotensi menyebabkan hilangnya informasi yang relevan.

Dari sisi implementasi, sistem telah berhasil direalisasikan dalam bentuk aplikasi berbasis web interaktif menggunakan Streamlit, yang memungkinkan pengguna melakukan deteksi digit secara real-time melalui proses unggah citra. Integrasi antara model deteksi dan mekanisme rekonstruksi numerik menunjukkan bahwa sistem mampu bekerja secara *end-to-end*, mulai dari input citra hingga menghasilkan nilai numerik yang akurat.

Selain kontribusi teknis, penelitian ini juga memberikan kontribusi pada bidang pendidikan melalui pengembangan media pembelajaran berbasis kecerdasan buatan. Sistem yang dikembangkan memungkinkan pengguna untuk memahami konsep *computer vision* dan implementasi *deep learning* secara langsung melalui pendekatan *experiential learning*, sehingga mendukung pembelajaran yang lebih interaktif dan aplikatif.

Untuk pengembangan selanjutnya, peningkatan kualitas dan keseimbangan dataset, optimasi model guna meningkatkan nilai *recall*, serta pengujian pada kondisi lingkungan yang lebih kompleks menjadi langkah penting untuk meningkatkan keandalan sistem. Selain itu, integrasi dengan perangkat medis secara langsung maupun sistem monitoring berbasis *Internet of Things* (IoT) berpotensi memperluas pemanfaatan sistem dalam skala yang lebih luas.

DAFTAR PUSTAKA

- [1] R. F. A. Saputra, M. Ridha, and J. T. Sulaimon, "Deep Learning Applications in Primary Education: A Systematic Literature Review of Emerging Trends, Challenges, and Opportunities," *Jurnal Pendidikan Progresif*, vol. 15, no. 3, pp. 1785–1810, Sep. 2025, doi: 10.23960/JPP.V15I3.PP1785-1810.
- [2] Y. Li *et al.*, "Mix-and-Interpolate: A Training Strategy to Deal With Source-Biased Medical Data," *IEEE J. Biomed. Health Inform.*, vol. 26, no. 1, pp. 172–182, Jan. 2022, doi: 10.1109/JBHI.2021.3119325.
- [3] G. Mishra, R. Tanwar, and P. Gupta, "Enhanced UAV target recognition via YOLOv8-SR with optimized super-resolution and hyperparameters," *Franklin Open*, vol. xxx, p. 100541, 2026, doi: 10.1016/j.fraope.2026.100541.
- [4] C. Zhou, Y. Fu, and K. Mi, "TOL-YOLO: A lightweight transformer oil leakage detection algorithm based on YOLOv8," *Signal Processing: Image Communication*, vol. xxx, p. 117533, 2026, doi: 10.1016/j.image.2026.117533.
- [5] W. Zhang, Y. Du, and Z. Wu, "Helmet-wearing detection with small object recognition via improved YOLOv8 in complex environments," *Digital Signal Processing*, vol. xxx, p. 106066, 2026, doi: 10.1016/j.dsp.2026.106066.
- [6] Suvarna Patil, Soham Waghule, Siddhesh Waje, Prasad Pawar, and Shreyash Domb, "Efficient Object Detection with YOLO: A Comprehensive Guide," *International Journal of Advanced Research in Science, Communication and Technology*, pp. 519–531, May 2024, doi: 10.48175/IJARSCT-18483.
- [7] K. Singh, R. Kumar, and S. Singh, "Advanced YOLOv8 architecture for multi-class brain tumor detection," *Journal of Associated Medical Sciences*, vol. xx, no. xx, pp. xx–xx, 2026, doi: 10.12982/jams.2026.056.
- [8] F. S. Mufidah, S. Mustoip, and N. Janan, "Development of Visual-Based Interactive Media to Understand the Water Cycle in Elementary Schools," *EduBase : Journal of Basic Education*, vol. 5, no. 2, pp. 167–172, Aug. 2024, doi: 10.47453/EDUBASE.V5I2.2880.
- [9] M. Yaseen, "WHAT IS YOLOV8: AN IN-DEPTH EXPLORATION OF THE INTERNAL FEATURES OF THE NEXT-GENERATION OBJECT DETECTOR," 2024.
- [10] H. Lv, Y. Luo, S. Jiang, Y. Bai, H. Bai, and L. Chen, "OGRA-YOLOv8: Overlapping Gridded and Rhombus Attention for Underwater Object Detection," in *Proc. IEEE ICASSP 2026*, 2026, doi: 10.1109/icassp55912.2026.11463298.
- [11] R. Naufaldihanif, D. Kurniawan, and K. D. Tania, "Performance Analysis of YOLO, Faster R-CNN, and DETR for Automated Personal Protective Equipment Detection," *Journal of Applied Informatics and Computing*, vol. 9, no. 6, pp. 3810–3820, Dec. 2025, doi: 10.30871/JAIC.V9I6.11593.
- [12] M. M. Kabir, A. Rahman, M. N. Hasan, and M. F. Mridha, "Computer vision algorithms in healthcare: Recent advancements and future challenges," *Comput. Biol. Med.*, vol. 185, p. 109531, Feb. 2025, doi: 10.1016/J.COMPBIOMED.2024.109531.
- [13] A. Fajriati, W. Wisroni, and C. Handrianto, "PEMANFAATAN TEKNOLOGI ARTIFICIAL INTELLIGENCE (AI) DALAM PEMBELAJARAN BERBASIS PESERTA DIDIK DI ERA DIGITAL,"

-
- WAHANA PEDAGOGIKA: Jurnal Ilmiah Pendidikan dan Pembelajaran*, vol. 6, no. 2, pp. 71–85, Dec. 2024, doi: 10.52166/WP.V6I2.7890.
- [14] R. Wu, Y. Cui, Z. Hu, J. Ren, Y. Zhang, and B. Li, “Heterogeneous multi-scale enhanced YOLOv8 for real-time maritime obstacle detection on unmanned surface vessels,” *Expert Systems with Applications*, vol. xxx, p. 132244, 2026, doi: 10.1016/j.eswa.2026.132244.
- [15] M. Khafifah, M. M. Parenreng, and A. Bastian, “Implementasi Computer Vision untuk Media Pembelajaran Pengenalan Angka Metode Jarimatika,” 2023.
- [16] M. Nasir, “Inovasi Pembelajaran Berbasis Artificial Intelligence (AI) untuk Meningkatkan Keterampilan Berpikir Kritis Siswa Sekolah Menengah,” *Jurnal Ilmiah Jendela Pendidikan*, vol. 14, no. 2, pp. 49–56, Oct. 2024, doi: 10.55129/JP.V14I2.3161.
- [17] C. Wen, H. Ding, B. Hou, W. Cui, X. Liang, J. Luo, J. Yang, W. Liang, C. Pang, Z. Lan, J. Peng, and Y. Xu, “YOLOv8-DSRI: An improved YOLOv8 instance segmentation algorithm for identifying silkworms in dense environments,” *Pattern Recognition*, vol. xxx, p. 113017, 2025, doi: 10.1016/j.patcog.2025.113017.
- [18] C. Y. Wang, A. Bochkovski, and H. Y. M. Liao, “YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors,” *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 2023-June, pp. 7464–7475, Jul. 2022, doi: 10.1109/CVPR52729.2023.00721.
- [19] X. Zhong, Y. Liu, Y. Chen, M. Dong, X. Hao, W. Shen, Z. Zhang, H. Sun, H. Li, and Y. Wang, “YOLO-pineapple: Enhanced pineapple detection in UAV images using an optimized YOLOv8 model,” *Expert Systems with Applications*, vol. xxx, p. 132486, 2026, doi: 10.1016/j.eswa.2026.132486.
- [20] M. Akram, K. Zahid, and C. Kahraman, “A PROMETHEE based outranking approach for the construction of Fangcang shelter hospital using spherical fuzzy sets,” *Artif. Intell. Med.*, vol. 135, Jan. 2023, doi: 10.1016/j.artmed.2022.102456.
- [21] S. Umak, M. Shaikh, K. Salve, and Dr. R. Gawande, “Health Monitoring System Using IOT,” *International Journal of Research Publication and Reviews*, vol. 6, no. 6, pp. 3952–3955, Jan. 2025, doi: 10.55248/GENGPI.6.0125.0604.