



Analisis dan Optimasi Jumlah Dataset pada YOLOv8 untuk Inspeksi Stamping Otomatis

Khairul Ma'mur*, Tatyantoro Andrasto, Arief Arfriandi

Fakultas Teknik, Program Studi Teknik elektro, Universitas Negeri Semarang, Semarang, Indonesia

Email: ^{1,*}khairulmakmur140@students.unnes.ac.id, ²tatyantoro@mail.unnes.ac.id, ³arfriandi@mail.unnes.ac.id

Email Penulis Korespondensi: khairulmakmur140@students.unnes.ac.id

Abstrak—Proses inspeksi kualitas hasil stamping pada industri manufaktur umumnya masih dilakukan secara manual, sehingga berpotensi menimbulkan kesalahan akibat kelelahan operator, ketidakkonsistenan pengamatan, dan rendahnya efisiensi waktu pemeriksaan. Penelitian ini bertujuan menerapkan algoritma You Only Look Once version 8 (YOLOv8) untuk mendeteksi dan mengklasifikasikan hasil stamping secara otomatis ke dalam kategori *Good* dan *Not Good* (NG). Tahapan penelitian meliputi pengumpulan dataset, *preprocessing* data, pelatihan model, validasi, dan pengujian *real-time*. Untuk menganalisis pengaruh jumlah data terhadap kinerja model, dilakukan tiga skenario pelatihan menggunakan 100, 1134, dan 1552 citra dengan parameter pelatihan yang sama. Evaluasi model dilakukan menggunakan metrik *Precision*, *Recall*, *mean Average Precision* pada *Intersection over Union* 50% (mAP50), *mean Average Precision* pada rentang *Intersection over Union* 50%–95% (mAP50–95), serta *confusion matrix*.

Hasil penelitian menunjukkan bahwa jumlah dataset memberikan pengaruh yang signifikan terhadap performa model. Model yang dilatih menggunakan 1552 citra menghasilkan kinerja terbaik dengan *Precision* 99,8%, *Recall* 100%, mAP50 sebesar 99,5%, dan mAP50–95 sebesar 96,6%, meningkat sebesar 11,7 poin persentase dibandingkan model yang dilatih menggunakan 100 citra yang memperoleh mAP50–95 sebesar 84,9%. Temuan ini menunjukkan bahwa penambahan jumlah dataset mampu meningkatkan kemampuan generalisasi model dalam mengenali variasi kualitas hasil stamping. Model terbaik kemudian diimplementasikan pada pengujian *real-time* menggunakan kamera laptop dan mampu mendeteksi serta mengklasifikasikan hasil stamping secara konsisten pada berbagai kondisi pencahayaan dengan akurasi pengujian sebesar 90%.

Kata Kunci: YOLOv8; Computer Vision; Stamping; Deteksi Objek; Real-Time

Abstract—Quality inspection of stamping products in the manufacturing industry is generally performed manually, which may lead to errors caused by operator fatigue, inconsistent observations, and low inspection efficiency. This study aims to implement the You Only Look Once version 8 (YOLOv8) algorithm to automatically detect and classify stamping products into Good and Not Good (NG) categories. The research stages included dataset collection, data preprocessing, model training, validation, and real-time testing. To analyze the effect of dataset size on model performance, three training scenarios were conducted using 100, 1,134, and 1,552 images with identical training parameters. Model performance was evaluated using Precision, Recall, mean Average Precision at 50% Intersection over Union (mAP50), mean Average Precision at 50%–95% Intersection over Union (mAP50–95), and a confusion matrix. The results indicate that increasing the number of datasets improves the performance of the YOLOv8 model. The model trained using 1,552 images achieved the best performance, with a Precision of 99.8%, Recall of 100%, mAP50 of 99.5%, and mAP50–95 of 96.6%, representing an improvement of 11.7 percentage points in mAP50–95 compared with the model trained using 100 images, which achieved an mAP50–95 of 84.9%. These findings indicate that increasing the dataset size enhances the model's generalization capability in recognizing variations in stamping quality. The best-performing model was subsequently implemented in real-time testing using a laptop camera and was able to consistently detect and classify stamping products under various lighting conditions, achieving a testing accuracy of 90%.

Keywords: YOLOv8; Computer Vision; Stamping; Object Detection; Real-Time

1. PENDAHULUAN

Perkembangan teknologi pada era Revolusi Industri 4.0 mendorong penerapan sistem otomatisasi dan teknologi cerdas dalam sektor manufaktur untuk meningkatkan produktivitas dan kualitas produk. Hal ini menjadi penting karena sektor manufaktur merupakan salah satu penyumbang utama perekonomian Indonesia dengan kontribusi sebesar 18,98% terhadap Produk Domestik Bruto (PDB) (Ayuningtyas, 2025). Salah satu proses penting dalam industri manufaktur adalah stamping, yaitu proses pencetakan informasi pada produk atau kemasan yang berperan dalam distribusi, pelacakan, dan pemenuhan standar kualitas. Namun, proses inspeksi hasil stamping masih banyak dilakukan secara manual sehingga rentan terhadap human error, ketidakkonsistenan pengamatan, serta rendahnya efisiensi pemeriksaan (Shaloo et al., 2024). Berbagai teknologi telah diterapkan untuk meningkatkan efisiensi proses produksi, seperti *Programmable Logic Controller* (PLC) dan *Internet of Things* (IoT). PLC mampu meningkatkan akurasi dan kestabilan operasi mesin, sedangkan IoT dapat meningkatkan produktivitas serta mengurangi downtime mesin (Dosluoglu & Macdonald, 2022; Onaifo et al., 2019). Meskipun demikian, kedua teknologi tersebut belum mampu melakukan validasi kualitas hasil stamping secara otomatis sehingga masih diperlukan sistem inspeksi yang cepat, akurat, dan *real-time*.

Inspeksi kualitas hasil stamping merupakan salah satu tantangan penting dalam sistem kontrol kualitas manufaktur karena karakteristik cacat yang muncul sering kali memiliki perbedaan visual yang sangat kecil. Berbeda dengan deteksi objek umum yang memiliki perbedaan bentuk dan ukuran yang jelas, cacat pada hasil stamping umumnya berupa tinta yang tidak merata, karakter yang terputus, hasil cetak yang buram, atau ketidaksesuaian posisi cetakan. Selain itu, permukaan material yang bersifat reflektif dapat menghasilkan pantulan cahaya dan noise visual yang berbeda-beda sehingga menyulitkan proses identifikasi secara otomatis. Variasi kondisi pencahayaan, sudut



pengambilan gambar, dan kualitas permukaan material berpotensi menyebabkan penurunan performa model deteksi objek karena fitur visual antar kelas menjadi semakin sulit dibedakan (Ren et al., 2022; Tian et al., 2020). Kondisi tersebut menyebabkan sistem inspeksi hasil stamping memerlukan model yang tidak hanya memiliki akurasi tinggi, tetapi juga mampu melakukan generalisasi terhadap berbagai variasi kondisi operasional yang ditemukan pada lingkungan industri.

Perkembangan teknologi *computer vision* berbasis *deep learning* menawarkan solusi yang menjanjikan untuk mengatasi permasalahan tersebut (Chai et al., 2021; Guha et al., 2023). Salah satu metode yang saat ini banyak digunakan dalam bidang deteksi objek adalah *You Only Look Once* (YOLO) (Dosluoglu & Macdonald, 2022). Metode ini dikenal memiliki kemampuan deteksi objek secara *real-time* dengan tingkat akurasi yang tinggi (Li et al., 2022; Wang et al., 2023; Xu et al., 2023). Berbagai penelitian menunjukkan bahwa perkembangan model YOLO dari generasi ke generasi menghasilkan peningkatan yang signifikan pada aspek akurasi, kecepatan inferensi, dan stabilitas deteksi objek (Ali & Zhang, 2024; Lasmana et al., 2025; Li et al., 2022; Wang et al., 2023). Studi komprehensif yang dilakukan oleh Ali dan Zhang (2024) menjelaskan bahwa setiap versi YOLO menghadirkan pembaruan arsitektur yang bertujuan meningkatkan efisiensi komputasi sekaligus memperbaiki kemampuan model dalam mengenali objek dengan berbagai ukuran dan kondisi lingkungan yang berbeda.

Generasi terbaru yang digunakan dalam penelitian ini adalah YOLOv8 yang diperkenalkan oleh Ultralytics pada tahun 2023. Dibandingkan generasi sebelumnya, YOLOv8 menghadirkan sejumlah pembaruan arsitektur yang menjadikannya unggul dalam berbagai aplikasi inspeksi industri seperti identifikasi cacat produk, inspeksi komponen manufaktur, dan pengenalan pola visual (Afifah & Erniwati, 2025; Diwan et al., 2023). Salah satu keunggulan utama YOLOv8 adalah penggunaan pendekatan *anchor-free detection* yang memungkinkan model melakukan prediksi *bounding box* secara langsung tanpa bergantung pada *anchor boxes*. Pendekatan tersebut terbukti mampu meningkatkan stabilitas pelatihan serta fleksibilitas model dalam mendeteksi objek dengan variasi ukuran dan bentuk yang beragam (Afifah & Erniwati, 2025). YOLOv8 menggunakan *backbone Cross Stage Partial with enhanced feature flow* yang dirancang untuk memperbaiki aliran gradien dan meningkatkan kemampuan model dalam menangkap detail visual yang kompleks. Karakteristik ini sangat relevan pada proses inspeksi hasil stamping, karena cacat yang muncul umumnya memiliki perbedaan visual yang sangat kecil, seperti tinta yang tidak merata, cetakan yang terputus, atau hasil cetakan yang buram (Ren et al., 2022; Tian et al., 2020). YOLOv8 juga menerapkan konsep *decoupled head* yaitu pemisahan proses klasifikasi dan regresi *bounding box*.

Pendekatan tersebut terbukti meningkatkan akurasi klasifikasi tanpa mengurangi ketepatan lokalisasi objek (Lasmana et al., 2025). Mekanisme tersebut diharapkan mampu membantu sistem dalam membedakan hasil stamping kategori *Good* dan *Not Good* (NG) secara lebih konsisten. Keunggulan lain dari YOLOv8 adalah kemampuannya untuk diimplementasikan pada perangkat *edge computing*. YOLOv8 telah menunjukkan kemampuan yang baik untuk diimplementasikan pada perangkat *single-board computer*, seperti Raspberry Pi 4 dan Raspberry Pi 5, dengan performa yang stabil serta mampu mendukung proses deteksi objek secara *real-time* (Artanto et al., 2025; Fernando & Utaminingrum, 2024). Selain pada bidang inspeksi industri, YOLOv8 juga telah diterapkan pada berbagai bidang lain seperti sistem transportasi untuk perhitungan kendaraan, pengelolaan lingkungan melalui deteksi sampah organik dan anorganik, serta pengawasan objek bergerak pada kondisi pencahayaan yang bervariasi (Prasetio & Pratiwi, 2025; Putra et al., 2024; Taufiqurrahman et al., 2024).

Berbagai penelitian tersebut menunjukkan bahwa YOLOv8 memiliki fleksibilitas tinggi untuk diterapkan pada sistem inspeksi otomatis yang membutuhkan kecepatan dan akurasi secara bersamaan. Teknologi ini mampu meningkatkan konsistensi inspeksi serta mengurangi ketergantungan terhadap pengamatan manual operator (Guha et al., 2023; Tian et al., 2020). Namun, penelitian yang secara khusus menganalisis pengaruh jumlah dataset terhadap performa YOLOv8 pada inspeksi hasil stamping masih relatif terbatas.

Berbagai penelitian sebelumnya telah menunjukkan keberhasilan YOLOv8 pada beragam aplikasi deteksi objek. Prasetio dan Pratiwi (2025) menerapkan YOLOv8 untuk klasifikasi sampah organik dan anorganik, sedangkan Putra et al. (2024) menggunakannya untuk penghitungan volume kendaraan. Pada sektor industri, Artanto et al. (2025) dan Fernando dan Utaminingrum (2024) memanfaatkan YOLOv8 pada sistem berbasis Raspberry Pi untuk kebutuhan inspeksi dan klasifikasi objek. Meskipun demikian, sebagian besar penelitian tersebut berfokus pada implementasi dan perbandingan performa model tanpa mengevaluasi secara sistematis pengaruh jumlah dataset terhadap kemampuan generalisasi model. Padahal, pada kasus inspeksi hasil stamping, jumlah dataset memiliki peran penting karena model harus mampu mengenali variasi cacat yang relatif kecil dan kompleks.

Dataset yang terlalu sedikit berpotensi menyebabkan model mengalami *overfitting* sehingga performa tinggi hanya diperoleh pada data pelatihan, sedangkan penambahan dataset yang lebih beragam dapat meningkatkan kemampuan model dalam mengenali pola cacat pada data yang belum pernah dilihat sebelumnya. Oleh karena itu, masih terdapat kebutuhan penelitian yang secara khusus mengkaji hubungan antara ukuran dataset dan performa YOLOv8 pada sistem inspeksi hasil stamping. Berdasarkan permasalahan tersebut, penelitian ini mengembangkan sistem inspeksi hasil stamping otomatis berbasis YOLOv8 sekaligus mengevaluasi pengaruh ukuran dataset terhadap performa model melalui tiga skenario pelatihan, yaitu 100, 1134, dan 1552 citra.

Berbeda dengan penelitian sebelumnya yang umumnya hanya melaporkan nilai akurasi akhir model, penelitian ini berfokus pada analisis hubungan antara ukuran dataset dan kemampuan deteksi YOLOv8 pada lingkungan inspeksi stamping yang memiliki karakteristik visual kompleks. Kontribusi penelitian tidak hanya terletak pada implementasi

sistem inspeksi otomatis secara real-time, tetapi juga pada identifikasi ukuran dataset yang mampu memberikan keseimbangan terbaik antara performa deteksi dan kemampuan generalisasi model.


2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian

Penelitian ini menggunakan metode *Research and Development* (R&D) untuk mengembangkan sistem validasi kualitas hasil stamping berbasis YOLOv8. Metode R&D digunakan karena berfokus pada proses pengembangan dan pengujian produk sehingga dapat menghasilkan sistem yang sesuai dengan kebutuhan pengguna (Sugiyono, 2021). Penelitian dilaksanakan di Banaran, Gunung Pati dan Laboratorium Jurusan Teknik Elektro Fakultas Teknik Universitas Negeri Semarang pada periode Oktober 2025–Maret 2026. Variabel penelitian meliputi dataset citra hasil stamping, proses pelatihan model YOLOv8, dan kinerja sistem yang diukur menggunakan nilai Akurasi, *Precision*, *Recall*, F1-Score, mAP50, dan mAP50-95. Kerangka penelitian terdiri dari tahap studi literatur, pengumpulan dataset, preprocessing dan anotasi data, pelatihan model YOLOv8, validasi model, proses *inference*, serta evaluasi kinerja sistem.

2.2 Alur Penelitian

Tahapan penelitian disusun secara sistematis mulai dari studi literatur, pengumpulan dataset, preprocessing dan anotasi data, pelatihan model YOLOv8, inferensi, hingga evaluasi kinerja sistem. Alur penelitian yang digunakan ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

2.2.1 Studi Literatur

Studi literatur dilakukan untuk memperoleh landasan teori yang berkaitan dengan computer vision, deep learning, deteksi objek, dan algoritma YOLOv8. Referensi yang digunakan berupa buku, jurnal, dan artikel ilmiah untuk mendukung perancangan sistem, proses pelatihan model, serta metode evaluasi yang digunakan dalam penelitian.

2.2.2 Pengumpulan Dataset

Dataset penelitian berupa citra hasil stamping yang diperoleh dari prototipe mesin stamping dan telah melalui proses anotasi ke dalam dua kelas, yaitu *Good* dan *Not Good* (NG). Untuk menganalisis pengaruh jumlah data terhadap performa YOLOv8, digunakan tiga variasi dataset, yaitu 100, 1134, dan 1552 citra. Dataset dibagi menjadi data pelatihan (*training*), validasi (*validation*), dan pengujian (*testing*) untuk mendukung proses pelatihan serta evaluasi kinerja model.

Pemilihan jumlah dataset 100, 1134, dan 1552 citra dilakukan untuk merepresentasikan tiga tingkat ketersediaan data yang berbeda dalam proses pelatihan model. Skenario 100 citra digunakan sebagai baseline untuk menggambarkan kondisi keterbatasan data yang umum ditemukan pada tahap awal pengembangan sistem inspeksi visual. Skenario 1134 citra dipilih untuk merepresentasikan kondisi dataset menengah yang berada di antara skenario dataset terbatas dan penggunaan seluruh dataset yang tersedia, sedangkan skenario 1552 citra menggunakan seluruh dataset yang berhasil dikumpulkan selama penelitian. Pendekatan ini digunakan untuk mengamati perubahan performa model secara bertahap seiring peningkatan jumlah data pelatihan serta mengevaluasi kemampuan generalisasi YOLOv8 pada berbagai tingkat ketersediaan dataset.

Tabel 1. Distribusi Dataset

Dataset	<i>Training</i>	<i>Validation</i>	<i>Testing</i>	Total
Skenario 1	80	10	10	100
Skenario 2	1010	62	62	1134
Skenario 3	1380	86	86	1552

Tabel 1 menunjukkan distribusi dataset yang digunakan pada setiap skenario penelitian. Dataset yang digunakan terdiri atas dua kategori, yaitu *Good* dan *Not Good* (NG). Kategori *Good* merupakan hasil stamping yang tercetak dengan jelas dan lengkap sesuai standar kualitas, sedangkan kategori *Not Good* (NG) mencakup hasil stamping yang mengalami cacat seperti tinta tidak merata, tinta meleber, karakter tidak lengkap, atau hasil cetak yang kurang terbaca. Pada setiap skenario, data testing dipisahkan dari data training dan validation sebelum proses pelatihan model dilakukan. Data testing tidak digunakan pada tahap training maupun validation, melainkan hanya digunakan untuk evaluasi performa model setelah proses pelatihan selesai. Pemisahan ini dilakukan untuk menghindari terjadinya data leakage serta memastikan bahwa hasil pengujian merepresentasikan kemampuan model dalam melakukan generalisasi terhadap data yang belum pernah dipelajari sebelumnya.



Gambar 2. Contoh Dataset Hasil Stamping


Gambar 2 menunjukkan contoh citra hasil stamping yang digunakan dalam penelitian. Citra kategori *Good* memiliki hasil cetakan yang jelas dan mudah dibaca, sedangkan kategori *Not Good* menunjukkan beberapa jenis cacat yang dapat memengaruhi kualitas hasil stamping.

2.2.3 Preprocessing Dataset

Tahap *preprocessing* dataset dilakukan menggunakan Roboflow untuk mempersiapkan data sebelum proses pelatihan YOLOv8. Proses ini meliputi anotasi objek dengan *bounding box* dan pelabelan ke dalam dua kelas, yaitu *Good* dan *Not Good* (NG). Selanjutnya dilakukan augmentasi data berupa rotasi, flipping, serta penyesuaian kecerahan dan kontras untuk meningkatkan variasi data (Chai et al., 2021). Proses augmentasi diterapkan secara konsisten pada data training di seluruh skenario dataset menggunakan konfigurasi yang sama. Data validation dan data testing tidak mengalami proses augmentasi agar dapat digunakan sebagai data evaluasi yang merepresentasikan kondisi aktual. Pendekatan ini dilakukan untuk memastikan bahwa perbedaan performa model yang diperoleh terutama dipengaruhi oleh variasi jumlah dataset, bukan oleh perbedaan perlakuan augmentasi pada masing-masing skenario Dataset kemudian dikonversi ke format yang kompatibel dengan YOLOv8 agar dapat digunakan pada tahap pelatihan model.

2.2.4 Training Model YOLOv8

Training model dilakukan menggunakan Google Colab untuk melatih YOLOv8 dalam mendeteksi dan mengklasifikasikan hasil stamping ke dalam kategori *Good* dan *Not Good* (NG). Dataset yang telah melalui proses *preprocessing* dibagi menjadi data *training*, *validation*, dan *testing*. Proses pelatihan dilakukan dengan mengatur parameter seperti *epoch*, *batch*, *image size* dan *patience* agar model dapat mempelajari karakteristik objek secara optimal. Tahapan pelatihan model YOLOv8 yang digunakan dalam penelitian ini ditunjukkan pada Gambar 3. Flowchart tersebut menggambarkan proses mulai dari pembagian dataset hingga terbentuknya model terlatih yang siap digunakan untuk klasifikasi.



Gambar 3. Flowchart Alur Training Model YOLOv8

Proses *training* diawali dengan pembagian dataset hasil stamping yang telah diberi label *Good* dan *Not Good* (NG) ke dalam data *training*, *validation*, dan *testing*. Data *training* digunakan untuk melatih model YOLOv8, data *validation* untuk memantau kinerja model selama pelatihan, dan data *testing* untuk menguji performa akhir model. Setelah proses pelatihan selesai, model digunakan untuk mengklasifikasikan hasil stamping ke dalam kategori *Good* atau *Not Good* (NG). Untuk menganalisis pengaruh jumlah data terhadap performa model, dilakukan tiga skenario pelatihan menggunakan 100, 1134, dan 1552 citra dengan parameter pelatihan yang sama. Penggunaan parameter pelatihan yang sama bertujuan untuk mengisolasi pengaruh jumlah dataset terhadap performa model sehingga perubahan nilai *precision*, *recall*, *mAP50*, dan *mAP50-95* dapat dianalisis secara lebih objektif.


2.2.5 Inferensi dan Visualisasi Hasil

Inferensi merupakan proses pengujian model YOLOv8 yang telah tervalidasi dengan menerapkannya pada data uji (*testing* dataset) serta pada sistem inspeksi visual prototipe mesin stamping. Pada tahap ini, model digunakan untuk melakukan deteksi objek secara langsung pada citra hasil stamping guna mengetahui kemampuan model dalam mengidentifikasi kondisi objek sesuai dengan kelas *Good* dan *Not Good* (NG). Proses inferensi dilakukan menggunakan model YOLOv8 terlatih dengan memasukkan citra uji sebagai input. Model kemudian menghasilkan keluaran berupa *bounding box*, label kelas *Good/Not Good*, dan nilai *confidence score* yang menunjukkan tingkat keyakinan model terhadap hasil deteksi.

2.2.6 Evaluasi Kinerja

Tahap evaluasi dilakukan untuk mengukur kinerja model YOLOv8 dalam mengklasifikasikan hasil stamping ke dalam kategori *Good* dan *Not Good* (NG). Evaluasi model dilakukan berdasarkan hasil pelatihan dan validasi menggunakan metrik *precision*, *recall*, *F1-score*, *mAP50*, dan *mAP50-95* untuk mengetahui kemampuan deteksi pada masing-masing skenario dataset. Selain itu, model terbaik hasil pelatihan diimplementasikan pada sistem inspeksi visual dan diuji secara *real-time* menggunakan kamera laptop serta prototipe mesin stamping. Hasil pengujian implementasi dibandingkan dengan kondisi aktual objek menggunakan *confusion matrix* dan nilai akurasi untuk mengevaluasi kemampuan sistem dalam melakukan klasifikasi secara langsung pada lingkungan pengujian.

2.3 Perancangan Sistem



Gambar 4. Diagram Blok Sistem

Diagram blok sistem dirancang untuk menggambarkan alur kerja sistem deteksi hasil stamping secara menyeluruh dengan konsep Input – Proses – Output. Gambar 4 menunjukkan hubungan antara tahapan input, proses, dan output yang digunakan dalam penelitian ini. Pada tahap input digunakan dataset hasil stamping yang diambil secara langsung pada prototipe mesin stamping. Pada tahap proses dilakukan eksperimen, dengan skenario eksperimen dengan jumlah data yang berbeda yaitu 100, 1134, dan 1552 citra. Kemudian pelatihan model menggunakan algoritma YOLOv8 pada masing-masing skenario dataset. Setelah proses pelatihan selesai, dilakukan evaluasi dan perbandingan performa model berdasarkan nilai *precision*, *recall*, *mAP50*, dan *mAP50-95* untuk mengetahui pengaruh jumlah dataset terhadap kinerja model. Tahap output menghasilkan model YOLOv8 dengan performa terbaik yang selanjutnya digunakan untuk melakukan klasifikasi hasil stamping ke dalam kategori *Good* atau *Not Good* secara *real time* pada laptop.

2.4 Parameter Pelatihan Model

Seluruh proses pelatihan model dilakukan menggunakan parameter yang sama pada setiap skenario eksperimen untuk memastikan perbandingan hasil dilakukan secara objektif dan konsisten. Dengan demikian, perbedaan performa yang diperoleh dapat dianalisis berdasarkan variasi jumlah dataset yang digunakan. Parameter pelatihan model YOLOv8 yang digunakan pada seluruh skenario eksperimen disajikan pada Tabel 2.

**Tabel 2.** Parameter Pelatihan Model

Parameter	Nilai
Platform	Google Colab
GPU	Tesla T4
Model	YOLOv8n
Jumlah Epoch	50
Image Size	640
Jumlah Batch	8
Jumlah Patience	50
Learning rate	0.01

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pelatihan, validasi, dan pengujian model YOLOv8 pada dataset hasil stamping yang terdiri dari dua kelas, yaitu *Good* dan *Not Good* (NG). Pelatihan dilakukan menggunakan tiga skenario jumlah dataset yang berbeda, yaitu 100 citra, 1134 citra, dan 1552 citra, dengan parameter pelatihan yang sama untuk menganalisis pengaruh jumlah data terhadap performa model. Seluruh model dievaluasi menggunakan metrik *Precision*, *Recall*, *F1-Score*, *mean Average Precision* pada *Intersection over Union* (IoU) 50% (mAP50), serta *mean Average Precision* pada rentang IoU 50%–95% (mAP50–95). Selain evaluasi selama proses pelatihan dan validasi, model terbaik akan diuji pada kondisi nyata melalui proses inferensi secara *real-time* menggunakan kamera laptop dan implementasi pada prototipe mesin stamping otomatis. Pengujian dilakukan untuk mengetahui kemampuan model dalam mendeteksi dan mengklasifikasikan hasil stamping pada berbagai kondisi operasional, termasuk variasi pencahayaan. Hasil pengujian kemudian dianalisis menggunakan *confusion matrix* untuk mengetahui tingkat akurasi klasifikasi serta jenis kesalahan yang masih terjadi pada sistem.

3.1 Perbandingan Hasil Pelatihan Model

Tabel 3. Perbandingan Hasil Pelatihan Model

Dataset	Presisi	Recall	F1-Score	mAP50	mAP50-95
100	0.988	1	0.994	0.995	0.849
1134	0.980	0.98387	0.982	0.994	0.857
1552	0.998	1	0.999	0.995	0.966

Tabel 3 menunjukkan hasil perbandingan performa model YOLOv8 pada tahap pelatihan menggunakan tiga skenario jumlah dataset yang berbeda. Berdasarkan hasil pelatihan pada tiga skenario dataset (100, 1134, dan 1552 citra), model YOLOv8 yang dilatih menggunakan 1552 citra menunjukkan performa terbaik dengan nilai *precision* 99,8%, *recall* 100%, *F1-Score* 99,9%, mAP50 99,5%, dan mAP50-95 96,6%. Nilai *F1-Score* yang tinggi menunjukkan bahwa model memiliki keseimbangan yang sangat baik antara *precision* dan *recall* dalam proses deteksi objek. Meskipun demikian, pada skenario 1134 citra terjadi sedikit penurunan nilai *precision* dibandingkan skenario 100 citra. Penurunan nilai *precision* pada skenario 1134 citra menunjukkan bahwa peningkatan jumlah data tidak selalu menghasilkan kenaikan performa secara linear. Kondisi tersebut mengindikasikan bahwa kompleksitas dan keragaman data juga memengaruhi kemampuan model dalam membedakan objek *Good* dan *Not Good*. Namun, ketika jumlah dataset ditingkatkan menjadi 1552 citra, performa model kembali meningkat pada hampir seluruh metrik evaluasi. Hasil ini menunjukkan bahwa jumlah data yang lebih besar memberikan representasi fitur yang lebih lengkap sehingga model mampu membangun pola klasifikasi yang lebih robust.

Peningkatan jumlah dataset menyebabkan model memperoleh variasi bentuk hasil stamping yang lebih banyak sehingga kemampuan generalisasi meningkat. Hal ini terlihat dari peningkatan nilai mAP50-95 dari 84,9% menjadi 96,6%. Hasil ini menunjukkan bahwa penambahan jumlah dataset meningkatkan kemampuan model dalam mendeteksi dan melokalisasi objek hasil stamping. Temuan ini sejalan dengan penelitian Ali dan Zhang (2024) yang menyatakan bahwa kualitas dan kuantitas dataset berpengaruh terhadap kemampuan generalisasi model YOLO. Semakin banyak variasi data yang digunakan selama pelatihan, semakin baik kemampuan model dalam mempelajari karakteristik visual objek sehingga proses klasifikasi dan lokalisasi dapat dilakukan dengan lebih akurat. Hal ini terlihat dari peningkatan nilai mAP50-95 pada model 1552 citra yang mencapai 96,6%, menunjukkan ketepatan posisi *bounding box* yang lebih baik dibandingkan model dengan jumlah data yang lebih sedikit. Oleh karena itu, model dengan 1552 citra dipilih sebagai model terbaik karena memberikan performa deteksi yang paling tinggi dan stabil.

3.2 Perbandingan Hasil Validasi Model

Tabel 4. Perbandingan Hasil Validasi Model

Dataset	Presisi	Recall	F1-Score	mAP50	mAP50-95
100	0.982	1	0.991	0.995	0.880
1134	0.980	0.984	0.982	0.994	0.857

Dataset	Presisi	Recall	F1-Score	mAP50	mAP50-95
1552	0.998	1	0.999	0.995	0.972

Tabel 4 menunjukkan hasil validasi model pada masing-masing skenario dataset. Berdasarkan hasil validasi yang diperoleh, model dengan 1552 citra menunjukkan performa terbaik dibandingkan dua skenario lainnya. Model ini menghasilkan nilai *precision*, *recall*, dan mAP50-95 yang lebih tinggi sehingga menunjukkan kemampuan deteksi yang lebih baik. Hasil tersebut mengindikasikan bahwa penambahan jumlah data pelatihan berpengaruh terhadap kemampuan model dalam mempelajari karakteristik objek hasil stamping. Semakin banyak variasi data yang digunakan selama proses pelatihan, semakin baik pula kemampuan model dalam mengenali perbedaan antara kelas *Good* dan *Not Good* (NG). Hasil penelitian ini sejalan dengan penelitian Lasmana et al. (2025) yang menyatakan bahwa peningkatan kualitas dan jumlah data pelatihan dapat meningkatkan performa deteksi objek pada model YOLO. Penggunaan 1552 citra memberikan variasi data yang lebih beragam dibandingkan skenario 100 dan 1134 citra, sehingga model mampu mempelajari karakteristik objek secara lebih optimal.

Konsistensi hasil antara proses pelatihan dan validasi menunjukkan bahwa model belum memperlihatkan indikasi overfitting yang kuat pada skenario pengujian yang digunakan. Namun, evaluasi lebih lanjut menggunakan teknik validasi berulang seperti k-fold cross-validation diperlukan untuk memperoleh estimasi performa yang lebih kuat dan mengurangi potensi bias akibat pembagian dataset tertentu. Hal ini terlihat dari performa model yang tetap tinggi ketika diuji menggunakan data validasi yang tidak digunakan selama proses pelatihan. Selain itu, nilai mAP50-95 yang tinggi menunjukkan bahwa model tidak hanya mampu mengklasifikasikan objek dengan baik, tetapi juga memiliki kemampuan lokalisasi objek yang akurat. Kemampuan tersebut penting dalam sistem inspeksi visual karena posisi objek yang terdeteksi turut memengaruhi kualitas hasil identifikasi. Berdasarkan hasil validasi tersebut, model dengan 1552 citra dipilih untuk tahap pengujian *real-time* karena memberikan performa yang paling baik dan stabil pada seluruh parameter evaluasi. Hasil ini menunjukkan bahwa penambahan jumlah dataset dapat meningkatkan kemampuan generalisasi model sehingga lebih siap digunakan pada kondisi pengujian yang sesungguhnya.

3.3 Pengujian Akurasi Deteksi Secara Real-Time

Tabel 5. Confusion Matrix Hasil Prediksi Model

Aktual	Prediksi <i>Good</i>	Prediksi <i>Not Good</i>
<i>Good</i>	5	0
<i>Not Good</i>	1	4

Tabel 5 menunjukkan confusion matrix hasil pengujian model pada kondisi real-time. Berdasarkan hasil confusion matrix pada Tabel 5, diperoleh nilai TP = 5, TN = 4, FP = 1, dan FN = 0 dengan akurasi sebesar 90%. Dari total 10 sampel yang diuji, sebanyak 9 sampel berhasil diklasifikasikan dengan benar oleh model. Hasil ini menunjukkan bahwa model YOLOv8 mampu melakukan deteksi dan klasifikasi hasil stamping dengan tingkat ketepatan yang cukup baik pada pengujian secara *real-time*. Tidak ditemukannya nilai FN menunjukkan bahwa seluruh objek yang diuji berhasil terdeteksi oleh sistem. Hal ini menandakan bahwa model memiliki kemampuan deteksi yang baik terhadap objek hasil stamping. Namun, masih terdapat satu kesalahan klasifikasi, yaitu objek *Not Good* yang diprediksi sebagai *Good*. Kesalahan tersebut kemungkinan disebabkan oleh karakteristik visual objek cacat yang memiliki kemiripan dengan objek normal sehingga model mengalami kesulitan dalam membedakannya secara tepat.



Gambar 5. Hasil Deteksi *Real-Time* Kategori *Good*



Gambar 6. Hasil Deteksi *Real-Time* Kategori *Not Good*

Gambar 5 dan Gambar 6 menunjukkan bahwa model mampu mendeteksi dan mengklasifikasikan objek hasil stamping secara *real-time* pada laptop. Pada pengujian objek kategori *Good* terdeteksi dengan nilai *confidence* sebesar


82%, sedangkan objek kategori *Not Good* terdeteksi dengan nilai *confidence* sebesar 74%. Hasil deteksi menunjukkan bahwa model dapat mengenali kedua kategori objek dan memberikan label yang sesuai dengan kondisi objek yang diamati. Meskipun terdapat perbedaan nilai *confidence* pada masing-masing kategori, model tetap mampu melakukan klasifikasi dengan benar. Hasil ini menunjukkan bahwa model telah berhasil mempelajari karakteristik visual objek *Good* dan *Not Good* selama proses pelatihan sehingga dapat digunakan untuk melakukan deteksi secara langsung pada kondisi pengujian *real-time*. Akurasi sebesar 90% menunjukkan bahwa model sudah mampu bekerja dengan cukup baik untuk proses inspeksi hasil stamping secara otomatis. Hasil ini juga menunjukkan bahwa model yang telah dilatih menggunakan dataset hasil stamping dapat mengenali objek pada kondisi pengujian secara langsung menggunakan kamera. Kemampuan ini menjadi penting karena sistem inspeksi yang dikembangkan ditujukan untuk digunakan secara *real-time* sehingga diperlukan model yang mampu memberikan hasil deteksi secara cepat dan konsisten. Meskipun demikian, jumlah sampel yang digunakan pada pengujian *real-time* masih relatif sedikit sehingga hasil yang diperoleh belum dapat menggambarkan seluruh kondisi yang mungkin terjadi pada lingkungan industri. Variasi bentuk cacat, kondisi pencahayaan, posisi objek, serta kualitas hasil stamping yang lebih beragam berpotensi memengaruhi performa model. Oleh karena itu, diperlukan pengujian lanjutan dengan jumlah sampel yang lebih banyak dan kondisi operasional yang lebih bervariasi agar kemampuan sistem dapat dievaluasi secara lebih menyeluruh. Dengan pengujian yang lebih luas, tingkat keandalan model dalam mendukung proses inspeksi kualitas hasil stamping dapat diketahui dengan lebih akurat.

3.4 Pengujian Pencahayaan

Tabel 6. Hasil Pengujian Pencahayaan

Kondisi Cahaya	<i>Good</i> Benar	<i>Not Good</i> Benar	Akurasi
Normal	5	4	90%
Terang	5	4	90%
Redup	4	5	90%

Berdasarkan hasil pengujian pencahayaan pada Tabel 6, model YOLOv8 memperoleh akurasi sebesar 90% pada seluruh kondisi pencahayaan, yaitu normal, terang, dan redup. Hasil tersebut menunjukkan bahwa perubahan intensitas cahaya tidak memberikan penurunan performa yang signifikan terhadap kemampuan model dalam mendeteksi dan mengklasifikasikan hasil stamping. Dari 10 sampel yang diuji pada masing-masing kondisi, sebanyak 9 objek berhasil diklasifikasikan dengan benar, sedangkan 1 objek mengalami kesalahan prediksi. Pada kondisi pencahayaan normal, model berhasil mengklasifikasikan seluruh objek *Good* dengan benar dan hanya mengalami satu kesalahan pada objek *Not Good*. Hasil ini menunjukkan bahwa model mampu bekerja dengan baik pada kondisi pencahayaan yang sesuai dengan kondisi saat pengambilan dataset. Sedangkan pada kondisi pencahayaan terang, model juga memperoleh akurasi sebesar 90% dengan jumlah objek yang berhasil diklasifikasikan sama seperti pada kondisi normal. Hal ini menunjukkan bahwa model masih mampu mengenali karakteristik objek meskipun terjadi peningkatan intensitas cahaya. Pada kondisi pencahayaan redup, akurasi yang diperoleh tetap sebesar 90%. Kondisi cahaya yang lebih rendah berpotensi memengaruhi kualitas citra yang diterima kamera, seperti berkurangnya ketajaman objek dan detail hasil stamping. Kondisi tersebut dapat menyebabkan beberapa karakteristik visual objek menjadi kurang jelas sehingga meningkatkan kemungkinan terjadinya kesalahan klasifikasi. Namun berdasarkan hasil pengujian yang dilakukan, model masih mampu mempertahankan performanya dengan baik pada kondisi tersebut.



Gambar 7. Hasil Deteksi Pada Berbagai Kondisi Pencahayaan

Gambar 7 menunjukkan hasil deteksi model YOLOv8 pada objek *Good* dan *Not Good* dengan kondisi pencahayaan normal, terang, dan redup. Pada seluruh kondisi pengujian, model masih mampu mendeteksi dan mengklasifikasikan objek sesuai dengan kelasnya. Hasil visual tersebut mendukung data pada Tabel 6 yang menunjukkan bahwa perubahan intensitas cahaya tidak menyebabkan penurunan akurasi yang signifikan. Meskipun kualitas citra mengalami perubahan akibat perbedaan pencahayaan, model tetap mampu memberikan prediksi yang konsisten dengan *confidence score* yang tinggi. Hasil pengujian ini menunjukkan bahwa model YOLOv8 memiliki kemampuan yang cukup stabil dalam menghadapi perubahan kondisi pencahayaan. Kemampuan tersebut kemungkinan dipengaruhi oleh proses *preprocessing* dan augmentasi data yang dilakukan selama tahap persiapan dataset. Variasi

kecerahan dan kontras yang diberikan pada proses augmentasi membantu model mempelajari karakteristik objek pada berbagai kondisi pencahayaan sehingga model menjadi lebih adaptif saat digunakan pada pengujian secara langsung. Temuan ini sejalan dengan penelitian Taufiqurrahman et al. (2024) yang menyatakan bahwa kondisi lingkungan dan pencahayaan dapat memengaruhi performa sistem deteksi objek secara *real-time*. Meskipun pencahayaan dapat memengaruhi kualitas citra yang diterima kamera, hasil penelitian menunjukkan bahwa model yang dikembangkan masih mampu mempertahankan tingkat akurasi yang relatif stabil. Oleh karena itu, model YOLOv8 yang digunakan dalam penelitian ini memiliki potensi untuk diterapkan pada sistem inspeksi otomatis yang bekerja pada kondisi pencahayaan yang berbeda-beda. Namun demikian, diperlukan pengujian lebih lanjut dengan jumlah sampel yang lebih banyak serta variasi kondisi pencahayaan yang lebih ekstrem untuk memperoleh gambaran performa sistem yang lebih menyeluruh.

3.5 Implementasi Model YOLOv8 Pada Prototipe

Tabel 7. Confusion Matrix Hasil Implementasi

Aktual	Prediksi <i>Good</i>	Prediksi <i>Not Good</i>
<i>Good</i>	5	0
<i>Not Good</i>	0	5

Berdasarkan hasil implementasi pada Tabel 7, diperoleh nilai TP = 5, TN = 5, FP = 0, dan FN = 0 sehingga model mencapai akurasi sebesar 100% pada skenario implementasi yang dilakukan. Seluruh objek hasil stamping yang terdiri dari kategori *Good* dan *Not Good* berhasil diklasifikasikan dengan benar oleh sistem tanpa ditemukan kesalahan prediksi. Tidak adanya nilai FP dan FN menunjukkan bahwa seluruh objek pada sampel pengujian berhasil dikenali sesuai dengan kelas sebenarnya. Namun, hasil tersebut perlu diinterpretasikan secara hati-hati karena jumlah sampel yang digunakan pada tahap implementasi hanya terdiri atas 10 data uji. Dengan jumlah sampel yang relatif terbatas, nilai akurasi 100% belum dapat dianggap merepresentasikan performa sistem secara menyeluruh pada berbagai kondisi operasional yang mungkin ditemui di lingkungan industri. Meskipun jumlah sampel pengujian masih terbatas, hasil implementasi menunjukkan bahwa model mampu membedakan objek *Good* dan *Not Good* pada seluruh sampel yang diuji serta memberikan hasil deteksi yang konsisten selama proses pengujian berlangsung. Kemampuan tersebut mengindikasikan bahwa model telah mempelajari karakteristik visual objek hasil stamping dengan baik selama proses pelatihan. Namun demikian, akurasi 100% yang diperoleh belum dapat dijadikan indikator mutlak bahwa model akan mempertahankan performa yang sama pada populasi data yang lebih besar dan lebih beragam. Meskipun akurasi yang diperoleh mencapai 100%, hasil tersebut tidak serta-merta menunjukkan bahwa model akan mempertahankan performa yang sama pada populasi data yang lebih besar. Jumlah sampel pengujian yang digunakan pada tahap implementasi hanya terdiri atas 10 citra sehingga secara statistik masih memiliki keterbatasan dalam merepresentasikan variasi cacat hasil stamping yang mungkin muncul pada proses produksi sesungguhnya. Oleh karena itu, nilai akurasi yang diperoleh lebih tepat digunakan sebagai indikator performa awal sistem dibandingkan sebagai ukuran akhir tingkat keandalan model.



Gambar 8. Hasil Implementasi Sistem Pada Objek *Good*



Gambar 9. Hasil Implementasi Sistem Pada Objek *Not Good*

Gambar 8 dan Gambar 9 menunjukkan hasil implementasi model YOLOv8 pada prototipe mesin stamping. Sistem mampu mendeteksi objek hasil stamping secara *real-time* dengan menampilkan label kelas, nilai *confidence*, serta FPS sebagai indikator kecepatan proses inferensi. Pada pengujian implementasi dengan objek kategori *Good* terdeteksi dengan nilai *confidence* sebesar 84% dan FPS 2,62, sedangkan objek kategori *Not Good* terdeteksi dengan



nilai *confidence* sebesar 74% dan FPS 2,84. Hasil tersebut menunjukkan bahwa model mampu mengklasifikasikan kedua kategori objek dengan baik pada kondisi pengujian yang dilakukan. Selain itu, sistem dapat menjalankan proses deteksi secara berkelanjutan pada prototipe sehingga mendukung proses inspeksi hasil stamping secara otomatis. Nilai FPS yang diperoleh menunjukkan bahwa model dapat melakukan inferensi dan menampilkan hasil deteksi secara langsung selama proses pengujian berlangsung.

Hasil implementasi yang lebih baik dibandingkan pengujian *real-time* sebelumnya kemungkinan dipengaruhi oleh kondisi lingkungan pengujian yang lebih terkontrol. Pada tahap implementasi, posisi kamera, jarak objek, serta kondisi pencahayaan dibuat lebih stabil sehingga gangguan yang dapat memengaruhi proses deteksi menjadi lebih sedikit. Kondisi tersebut membantu model dalam mengenali objek secara lebih akurat dibandingkan pengujian pada lingkungan yang memiliki variasi kondisi yang lebih besar. Keberhasilan model mencapai akurasi 100% menunjukkan bahwa YOLOv8 memiliki potensi yang baik untuk diterapkan sebagai sistem inspeksi otomatis pada proses kontrol kualitas hasil stamping. Sistem mampu melakukan deteksi dan klasifikasi secara *real-time* tanpa memerlukan pemeriksaan manual oleh operator. Dengan adanya sistem ini, proses inspeksi dapat dilakukan secara lebih cepat dan konsisten sehingga berpotensi membantu meningkatkan efisiensi proses produksi. Akan tetapi, hasil yang diperoleh masih perlu dianalisis secara hati-hati karena jumlah sampel pengujian yang digunakan relatif terbatas. Akurasi 100% pada pengujian ini belum dapat dijadikan acuan bahwa sistem akan selalu menghasilkan performa yang sama pada kondisi industri yang sebenarnya. Variasi kondisi operasional seperti perubahan pencahayaan, posisi objek yang berbeda, kualitas hasil stamping yang lebih beragam, serta jumlah objek yang lebih banyak dalam satu waktu dapat memengaruhi performa sistem. Oleh karena itu, diperlukan pengujian lanjutan dengan jumlah sampel yang lebih besar dan kondisi pengujian yang lebih bervariasi agar tingkat keandalan sistem dapat dievaluasi secara lebih menyeluruh sebelum diterapkan pada lingkungan industri secara nyata.

Selain keterbatasan jumlah sampel pengujian, penelitian ini juga menggunakan satu skenario pembagian dataset sehingga belum mengevaluasi stabilitas performa model pada berbagai kombinasi data pelatihan dan pengujian. Oleh karena itu, penelitian selanjutnya dapat menerapkan metode validasi yang lebih komprehensif, seperti *k-fold cross-validation*, untuk memperoleh estimasi performa yang lebih robust serta mengevaluasi potensi *overfitting* secara lebih mendalam. Pendekatan tersebut dapat memberikan gambaran yang lebih representatif mengenai kemampuan generalisasi model ketika diterapkan pada data baru yang memiliki karakteristik berbeda dari data pelatihan.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa jumlah dataset berpengaruh terhadap kinerja model YOLOv8 dalam mendeteksi dan mengklasifikasikan hasil stamping. Pengujian dilakukan menggunakan tiga skenario dataset, yaitu 100 citra, 1134 citra, dan 1552 citra. Hasil menunjukkan bahwa model yang dilatih menggunakan dataset berisi 1552 citra menghasilkan performa terbaik dengan nilai *precision* sebesar 99,8%, *recall* 100%, *mAP50* sebesar 99,5%, dan *mAP50-95* sebesar 96,6%. Peningkatan jumlah dataset memberikan representasi variasi hasil stamping yang lebih beragam sehingga kemampuan generalisasi model meningkat dan menghasilkan performa deteksi yang lebih baik dibandingkan skenario dengan jumlah data yang lebih sedikit. Hasil pengujian *real-time* menunjukkan bahwa model mampu melakukan deteksi dan klasifikasi hasil stamping kategori Good dan Not Good (NG) dengan akurasi sebesar 90%, sedangkan pada tahap implementasi pada prototipe mesin stamping otomatis diperoleh akurasi 100% pada skenario pengujian yang dilakukan. Namun, hasil implementasi tersebut perlu diinterpretasikan secara hati-hati karena jumlah sampel pengujian masih terbatas dan dilakukan pada lingkungan yang relatif terkontrol. Hasil tersebut menunjukkan bahwa model YOLOv8 memiliki potensi untuk diterapkan sebagai sistem inspeksi visual otomatis yang mampu mendukung proses kontrol kualitas hasil stamping secara *real-time*. Meskipun demikian, performa model masih berpotensi dipengaruhi oleh kondisi operasional yang lebih kompleks, seperti variasi pencahayaan yang ekstrem, posisi objek yang tidak konsisten, serta jenis cacat hasil stamping yang belum terwakili dalam dataset pelatihan. Oleh karena itu, penelitian selanjutnya perlu melibatkan jumlah data yang lebih besar dan metode validasi yang lebih komprehensif, seperti *k-fold cross-validation*, untuk memperoleh estimasi performa model yang lebih robust.

REFERENCES

- Afifah, V., & Erniwati, S. (2025). YOLOv8 for Object Detection: A Comprehensive Review of Advances, Techniques, and Applications. *IJACI: International Journal of Advanced Computing and Informatics*, 2(1), 53–61. <https://doi.org/10.71129/ijaci.v2i1.pp53-61>
- Ali, M. L., & Zhang, Z. (2024). The YOLO Framework: A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection. *Computers*, 13(12). <https://doi.org/10.3390/computers13120336>
- Artanto, G. A., Hanafi, Z., Iman, R. M., & Stefanie, A. (2025). Implementasi YOLOv8 Pada Sistem Deteksi Penyakit Ikan Mas Koki Menggunakan Raspberry Pi 5. *Jurnal Informatika Dan Teknik Elektro Terapan*, 13(3). <https://doi.org/10.23960/jitet.v13i3.6770>
- Ayuningtyas, A. D. (2025). *Industri Manufaktur Sumbang 18,98% terhadap PDB Indonesia*. GoodStats. <https://goodstats.id/article/industri-manufaktur-sumbang-18-98-terhadap-pdb-indonesia-tSkW8>
- Chai, J., Zeng, H., Li, A., & Ngai, E. W. T. (2021). Deep learning in computer vision: A critical review of emerging



- techniques and application scenarios. *Machine Learning with Applications*, 6(August), 100134. <https://doi.org/10.1016/j.mlwa.2021.100134>
- Diwan, T., Anirudh, G., & Tembhurne, J. V. (2023). Object detection using YOLO: challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*, 82(6), 9243–9275. <https://doi.org/10.1007/s11042-022-13644-y>
- Dosluoglu, T., & Macdonald, M. (2022). *Circuit Design for Predictive Maintenance*. 1–4. <https://doi.org/https://doi.org/10.54364/AAIML.2022.1136>
- Fernando, L. L., & Utaminingrum, F. (2024). *Rancang Bangun Sistem Klasifikasi Sampah Menggunakan YOLOv8 Berbasis Raspberry Pi 4*. 1(1), 1–5. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/13779>
- Guha, B., Moore, S., & Huyghe, J. M. (2023). Application and validation of machine vision inspection for efficient in-process monitoring of complex biomechanical device manufacturing. *Journal of Engineering and Applied Science*, 70(1), 1–19. <https://doi.org/10.1186/s44147-023-00242-4>
- Lasmana, D., Husni, N. L., & Kusumanto, R. (2025). Deteksi Objek Menggunakan YOLOv5 dan YOLOv8 pada Perangkat Pemantauan Lingkungan. *Jurnal Elektronika Dan Otomasi Industri*, 12(2), 276–282. <https://doi.org/10.33795/elkolind.v12i2.7615>
- Li, C., Li, L., Jiang, H., Weng, K., Geng, Y., Li, L., Ke, Z., Li, Q., Cheng, M., Nie, W., Li, Y., Zhang, B., Liang, Y., Zhou, L., Xu, X., Chu, X., Wei, X., & Wei, X. (2022). YOLOv6: A Single-Stage Object Detection Framework for Industrial Applications. <http://arxiv.org/abs/2209.02976>
- Onaifo, F., Okandeji, A. ., Folorunsho, O., Essien, U. ., Oyedele, A. ., & Abolade, O. . (2019). *Comparison Of The Reliability Of Programmable Logic Controller And Electromagnetic Relay Control In Industrial Production Line*. 38(4), 1030–1035. <https://doi.org/https://doi.org/10.4314/njt.v38i4.28>
- Prasetio, B., & Pratiwi, N. (2025). Deteksi Sampah Organik dan Anorganik Menggunakan Model YOLOv8. *JlPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 10(1), 494–506. <https://doi.org/10.29100/jipi.v10i1.5965>
- Putra, W. P. N., Pradana, A. I., & Nurchim, N. (2024). Implementasi Sistem Penghitungan Volume Kendaraan Menggunakan YOLOv8. *Jurnal Fasikom*, 14(2), 443–450. <https://doi.org/10.37859/jf.v14i2.7395>
- Ren, Z., Fang, F., Yan, N., & Wu, Y. (2022). State of the Art in Defect Detection Based on Machine Vision. In *International Journal of Precision Engineering and Manufacturing - Green Technology* (Vol. 9, Issue 2). Korean Society for Precision Engineering. <https://doi.org/10.1007/s40684-021-00343-6>
- Shaloo, M., Princz, G., Hörbe, R., & Erol, S. (2024). ScienceDirect ScienceDirect Flexible Flexible automation automation of of quality quality inspection inspection in in parts parts assembly assembly using using CNN-based machine machine learning learning. *Procedia Computer Science*, 232, 2921–2932. <https://doi.org/10.1016/j.procs.2024.02.108>
- Sugiyono. (2021). *Metode Penelitian Kuantitatif Kualitatif dan R&D* (3rd ed.). Bandung: Alfabeta.
- Taufiqurrahman, T., Hadi, A. P., & Siregar, R. E. (2024). Evaluasi Performa YOLOv8 Dalam Deteksi Objek Di Depan Kendaraan Dengan Variasi Kondisi Lingkungan. *Jurnal Minfo Polgan*, 13(2), 1755–1773. <https://doi.org/10.33395/jmp.v13i2.14228>
- Tian, H., Wang, D., Lin, J., Chen, Q., & Liu, Z. (2020). Surface defects detection of stamping and grinding flat parts based on machine vision. *Sensors (Switzerland)*, 20(16), 1–17. <https://doi.org/10.3390/s20164531>
- Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2023). 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, 2023-June*, 7464–7475. <https://doi.org/10.1109/CVPR52729.2023.00721>
- Xu, X., Jiang, Y., Chen, W., Huang, Y., Zhang, Y., & Sun, X. (2023). DAMO-YOLO: A Report on Real-Time Object Detection Design. <http://arxiv.org/abs/2211.15444>