

Penerapan Algoritma YOLOV5 Berbasis Computer Vision Untuk Pemantauan Real Time Child Part Assembly Bumper Pada Industri Otomotif

Implementation of Computer Vision-Based YOLOv5 Algorithm for Real-Time Monitoring of Bumper Child Part Assembly Defects in the Automotive Industry

Abby Muhammad Titan*, Dendy K Pramudito, Muhamad Fatchan

Fakultas Teknik, Program Studi Teknik Informatika, Universitas Pelita Bangsa, Bekasi, Indonesia

Jalan Inspeksi Kalimalang Tegal Danas, Arah Deltamas, Cikarang Pusat, Kabupaten Bekasi, Indonesia

Email: ¹abby.mt9907@mhs.pelitabangsa.ac.id, ²doktor.haji.dendy@pelitabangsa.ac.id, ³fatchan@pelitabangsa.ac.id

Email Penulis Korespondensi: abby.mt9907@mhs.pelitabangsa.ac.id

Received: 03/09/2026, Revised: 16/09/2026, Accepted: 20/09/2026, Published: 11/10/2026

Abstrak—Prosedur perakitan komponen berskala kecil atau child part assembly pada industri manufaktur komponen otomotif merupakan tahapan kritis yang sangat rentan terhadap kelalaian manusia akibat ketergantungan operasional pada metode inspeksi visual manual oleh pekerja. Keterbatasan fokus dan kelelahan kognitif operator kerap memicu kelolosan komponen cacat ke lini berikutnya, yang berdampak pada lonjakan biaya pengerjaan ulang serta risiko kegagalan fungsi saat unit dirakit secara utuh. Penelitian ini bertujuan untuk merancang serta mengimplementasikan sebuah sistem pemantauan cerdas secara langsung berbasis Computer Vision dan algoritma Deep Learning YOLOv5 guna memverifikasi kelengkapan komponen klip secara otomatis. Tahapan prapemrosesan citra dilakukan secara komprehensif menggunakan pustaka OpenCV dan manipulasi matriks NumPy untuk menormalisasi variasi pencahayaan buatan. Batasan lingkungan pengujian (testbed) difokuskan pada stasiun kerja perakitan bumper kendaraan dengan iluminasi cincin terdistribusi dan laju konveyor tetap guna memastikan keterulangan akuisisi visual. Model yang dilatih kemudian diintegrasikan ke dalam antarmuka web interaktif menggunakan kerangka kerja Flask yang menyajikan umpan balik visual seketika serta pencatatan log inspeksi otomatis ke basis data SQLite. Hasil pengujian menunjukkan bahwa sistem berhasil mencapai akurasi deteksi sebesar 98,6 persen, presisi 98,9 persen, sensitivitas recall 99,8 persen, dan F1-score 99,3 persen dengan waktu inferensi 12,5 milidetik (65 Frames Per Second). Kontribusi utama penelitian ini terletak pada pengembangan kerangka kerja inspeksi terpadu yang memadukan model deteksi YOLOv5 berbobot komputasi ringan dengan instrumen analitik kelelahan kerja (Fatigue Analytics) serta pencatatan riwayat otomatis secara seketika. Solusi terintegrasi ini tidak sekadar bertindak sebagai pengawas mutu visual, melainkan juga menyediakan instrumen diagnostik ergonomi kerja berbasis data empiris untuk menekan angka kecacatan produk hingga di bawah dua persen pada rantai produksi.

Kata Kunci: Child Part Assembly; Computer Vision; Deep Learning; Real-Time Monitoring; YOLOv5

Abstract—The assembly process of small-scale components, widely known as the bumper child part assembly stage in the automotive manufacturing industry, is highly vulnerable to human error and daily quality inspection inconsistencies. This vulnerability is primarily driven by excessive operational reliance on manual visual inspection conducted by human operators over extended periods. Such dependency frequently leads to defective products escaping to subsequent production lines, ultimately causing financial losses for the company. To address this critical issue, this study aims to design and implement an intelligent real-time monitoring system based on computer vision technology and the You Only Look Once version 5 (YOLOv5) deep learning algorithm to automatically detect anomalies in vehicle bumper component assembly. The image preprocessing stage is comprehensively performed using the OpenCV library and matrix manipulation to normalize variations in artificial lighting intensity on the production floor. The testbed in this study is focused on an assembly workstation equipped with ring illumination and a controlled conveyor speed to ensure visual data validity. This artificial intelligence system is then integrated into an interactive web monitoring interface that provides instantaneous feedback along with automated inspection logging into a database. Empirical test results in an actual production environment demonstrate that the system achieves an average detection accuracy of 98.6%, a precision of 98.9%, a recall of 99.8%, and an F1-score of 99.3%. The inference time is remarkably short at 12.5 milliseconds, enabling a processing speed of up to 65 frames per second. The principal contribution of this research lies in the development of an integrated inspection framework that synergizes a lightweight YOLOv5 detection model with a real-time Fatigue Analytics instrument and automated database logging. This integrated solution functions not only as a passive visual quality verifier but also as an empirical ergonomics diagnostic tool that suppresses component defect rates below two percent in actual manufacturing environments.

Keywords: Child Part Assembly; Computer Vision; Deep Learning; Real-Time Monitoring; YOLOv5

1. PENDAHULUAN

Industri manufaktur otomotif modern saat ini tengah menghadapi tantangan operasional yang sangat masif untuk terus meningkatkan efisiensi, menekan biaya, dan mempertahankan kualitas produksi demi memenuhi permintaan pasar global yang semakin kompleks. Salah satu aspek paling fundamental namun sangat menantang dalam proses manufaktur kendaraan adalah tahapan perakitan komponen, secara khusus pada perakitan komponen berskala kecil (child part assembly). Tahapan ini sangat menuntut ketelitian visual dan kecekatan mekanis yang tinggi guna



memastikan bahwa setiap subsistem penyusun produk akhir memenuhi spesifikasi standar kualitas yang ketat sebelum dirakit menjadi unit kendaraan utuh [1]. Kesalahan sekecil apa pun pada tahap perakitan mikro ini, seperti baut yang tidak terpasang sempurna atau klip penahan yang terlewat, dapat menyebabkan rentetan cacat produk turunan, melonjaknya biaya produksi akibat pengerjaan ulang, hingga menurunnya tingkat kepuasan dan keselamatan pelanggan secara drastis di masa depan [2].

Untuk menjawab tantangan inspeksi presisi tersebut, teknologi visi komputer (computer vision) dan pembelajaran mesin (machine learning) telah berkembang pesat serta menawarkan solusi inovatif dalam pemantauan proses perakitan secara berkelanjutan [3]. Visi komputer memungkinkan sistem komputasi untuk mengenali, mengurai, dan menganalisis representasi gambar maupun aliran video dari proses perakitan fisik selayaknya indra penglihatan manusia. Sementara itu, pembelajaran mesin memungkinkan sistem jaringan saraf untuk mengekstraksi pola dari kumpulan data spasial tersebut guna membuat keputusan yang presisi secara mandiri [4]. Kombinasi terpadu dari kedua ranah kecerdasan buatan ini dapat dimanfaatkan secara optimal untuk mendeteksi kesalahan perakitan, memastikan kelengkapan komponen, serta meningkatkan efisiensi dan kapasitas proses produksi secara keseluruhan di lingkungan lantai pabrik yang bising dan dinamis [5].

Penerapan manufaktur cerdas (smart manufacturing) mengintegrasikan analitik data seketika dan otomasi guna memperkuat pengambilan keputusan pada lini perakitan komponen industri [6]. Dalam konteks pengawasan mutu, teknologi visi komputer mentransformasikan data visual mentah menjadi informasi terstruktur untuk tugas klasifikasi, lokalisasi posisi, dan deteksi objek [7]. Pendekatan inspeksi visual otomatis (automated visual inspection) sangat relevan ketika pengujian harus dijalankan berulang kali dengan konsistensi waktu respons yang tinggi. Algoritma deteksi objek memformulasikan penentuan lokasi kotak pembatas (bounding box) dan estimasi probabilitas kelas target secara serentak [8]. Perkembangan arsitektur YOLO, mulai dari YOLOv3 hingga YOLOv4, secara konsisten memperkenalkan perbaikan struktur pengekstraksi fitur untuk menyeimbangkan antara tingkat akurasi dan kecepatan komputasi [9]. Pemanfaatan teknik pembelajaran transfer (transfer learning) dan augmentasi data berbasis citra lini produksi terbukti efektif dalam mengatasi keterbatasan sampel pelatihan serta menangani ketidakseimbangan kelas objek [10].

Tahap child part assembly merupakan salah satu titik persimpangan paling kritis dalam proses manufaktur, di mana berbagai komponen berukuran kecil seperti klip besi penahan dan braket plastik harus dirakit ke dalam panel bumper kendaraan dengan ketepatan metrik yang tinggi. Pada kenyataannya, proses operasional di salah satu perusahaan manufaktur komponen otomotif masih sering bergantung pada inspeksi visual manual yang tidak hanya memakan banyak waktu siklus, tetapi juga sangat rentan terhadap kelalaian manusia [5]. Kondisi lingkungan pabrik yang menuntut kewaspadaan konstan sering kali memicu kelelahan kognitif pada pekerja, sehingga standarisasi deteksi kesalahan menjadi tidak merata antar operator. Melalui pemantauan cerdas berbasis visi komputer, sistem komputasi mampu mendeteksi ketidaksesuaian rakitan komponen sejak dini sebelum produk tersebut berlanjut ke lini produksi otomatis berikutnya. Kehadiran teknologi inspeksi cerdas ini diharapkan mampu menciptakan simbiosis antara manusia dan mesin yang jauh lebih tangguh dalam mencegah terjadinya anomali manufaktur [11].

Berdasarkan teori fundamental pengolahan citra digital untuk ekstraksi fitur objek, pemahaman algoritma mengenai konektivitas piksel sangatlah esensial. Proses pembuatan label pelacakan komponen atau segmentasi citra umumnya menggunakan pendekatan analitik konektivitas empat arah atau konektivitas delapan arah. Pada konsep konektivitas empat arah, sebuah piksel sentral dievaluasi dan dipetakan agar terhubung dengan empat piksel tetangganya secara eksklusif pada sumbu horizontal dan vertikal. Jika piksel yang berdampingan memiliki identitas atau intensitas warna yang identik, maka piksel pusat akan mewarisi label dari piksel sekitarnya [12]. Sementara itu, pada pendekatan konektivitas delapan arah, jangkauan evaluasi piksel diperluas hingga melintasi empat arah diagonal tambahan. Pendekatan spasial yang lebih luas ini memungkinkan algoritma komputer untuk melacak tepi objek mekanik yang melengkung, tajam, atau asimetris dengan jauh lebih akurat, yang merupakan landasan bagi arsitektur ekstraksi fitur modern [7].

Memasuki beberapa tahun terakhir, penelitian mengenai teknologi pembelajaran mendalam (deep learning) berbasis Convolutional Neural Network (CNN) telah menghasilkan berbagai kemajuan signifikan sebagai batas mutakhir dalam domain deteksi cacat permukaan dan perakitan industri [13]. Sejumlah kajian literatur terkini telah membuktikan potensi sekaligus batasan dari berbagai arsitektur deteksi objek. Sebagai bukti, penelitian sebelumnya mengimplementasikan algoritma YOLOv7 untuk mendeteksi cacat pada lampu berjalan otomotif (automotive running lights) dan berhasil mengidentifikasi goresan mikroskopis dengan akurasi yang memadai [14]. Namun, kelemahan utama dari pendekatan ini adalah tingginya beban komputasi arsitektur YOLOv7 yang membuatnya sulit diintegrasikan ke dalam perangkat keras komputasi tepi dengan memori terbatas. Studi komparatif lainnya menerapkan algoritma YOLOv8 yang dilengkapi dengan modul atensi kompleks untuk inspeksi cacat pada papan sirkuit cetak (PCB) berskala kecil [15]. Walaupun model ini sangat sensitif terhadap objek minor, arsitektur tersebut sangat rentan terhadap masalah penurunan kecepatan (lag) saat memproses aliran video industri dengan resolusi tinggi.

Lebih lanjut, eksperimen pendeteksian objek di sektor manufaktur baja juga telah mengeksplorasi penggunaan model AFF-YOLO yang menggabungkan mekanisme atensi spasial untuk menyoroti cacat goresan pada permukaan logam [16]. Meskipun menjanjikan peningkatan deteksi fitur, sistem ini masih menunjukkan kelemahan fatal berupa tingginya rasio peringatan palsu akibat ketidakmampuan model dalam membedakan antara

cacat fisik aktual dengan pantulan cahaya spekulat yang memantul dari permukaan baja murni. Dalam konteks inspeksi komponen manufaktur otomotif berbahan krom atau logam reflektif, distorsi visual akibat pencahayaan artifisial merupakan tantangan yang sangat mengganggu [17]. Penelitian lain di bidang dirgantara menggunakan modifikasi CNN untuk mendeteksi cacat permukaan, namun terkendala oleh kurangnya mekanisme integrasi untuk mengambil keputusan waktu nyata guna menghentikan konveyor otomatis [18]. Selain itu, investigasi deteksi baut las (weld nut) pada industri otomotif dengan CNN standar mencatatkan waktu respons 0,14 detik yang kurang fleksibel untuk penelusuran eror manusia [19], sedangkan pengujian deteksi cacat permukaan material dengan model two-stage ataupun YOLOv5 dengan modul atensi kompleks kerap mengalami kendala efisiensi saat diterapkan pada aliran video langsung [20].

Mencermati perkembangan studi literatur dari penelitian sejenis, tampak jelas adanya kesenjangan penelitian (research gap) yang mendalam antara kapabilitas algoritma di lingkungan pengujian terkontrol dengan tuntutan operasional nyata di lantai pabrik. Kajian deteksi cacat lampu berjalan otomotif berbasis YOLOv7 berhasil mengenali anomali mikroskopis, namun terhambat oleh bobot komputasi arsitektur yang berat sehingga memicu latensi tinggi pada perangkat komputasi tepi berdaya rendah [14]. Penerapan model YOLOv8 dengan mekanisme atensi pada papan sirkuit cetak terbukti sensitif terhadap komponen mikro, tetapi arsitektur tersebut sangat rentan terhadap penurunan drastis laju bingkai citra (frame rate drop) saat mengeksekusi aliran video beresolusi tinggi di stasiun kerja aktif [15]. Sementara itu, implementasi model AFF-YOLO pada lembaran baja manufaktur masih memperlihatkan tingginya frekuensi alarm palsu akibat kegagalan filter konvolusi dalam membedakan antara kecacatan fisik aktual dengan pantulan cahaya spekulat pada permukaan logam yang berkilau [16]. Di sisi lain, penerapan model CNN standar pada pengujian baut las (weld nut) otomotif memerlukan waktu respons hingga 0,14 detik dan hanya menghasilkan luaran biner statis tanpa mekanisme integrasi antarmuka pemantauan mandiri maupun sistem pencatatan log historis [19]. Kesenjangan paling fundamental dari rangkaian riset terdahulu tersebut adalah ketiadaan pemanfaatan data inspeksi visual sebagai instrumen analitik ergonomi, padahal mayoritas kegagalan perakitan pada stasiun kerja manual berakar dari penurunan konsentrasi pekerja akibat kelelahan fisik dan kognitif pada jam kerja kritis. Belum ada sistem inspeksi terpadu yang mampu memitigasi distorsi optik spekulat, menjaga stabilitas inferensi di atas batas real-time, sekaligus memetakan fluktuasi kelelahan operator secara simultan pada lini perakitan komponen otomotif.


Guna menutup kesenjangan penelitian tersebut, riset ini menghadirkan kontribusi komprehensif bagi pengembangan sistem kendali mutu cerdas. Arsitektur deteksi yang dikembangkan memadukan model YOLOv5 dengan fungsi prapemrosesan OpenCV dan manipulasi matriks NumPy untuk mengeliminasi gangguan pantulan spekulat pada klip logam tanpa membebani komputasi. Sistem inferensi ini diintegrasikan langsung dengan peladen web Flask dan basis data SQLite guna menghasilkan antarmuka pemantauan seketika dengan waktu inferensi 12,5 milidetik pada laju 65 FPS beserta perekaman data inspeksi otomatis. Sistem ini turut menyematkan modul analitik kelelahan kerja (Fatigue Analytics) yang memanfaatkan rekam jejak anomali komponen untuk memetakan titik rawan kelalaian manusia (human error) sepanjang jam operasional shift kerja, sehingga menyediakan landasan data empiris bagi perbaikan jadwal rotasi dan peningkatan ergonomi kerja di lantai produksi.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Pelaksanaan penelitian ini disusun secara sistematis melalui tahapan rekayasa berkesinambungan yang meliputi observasi stasiun kerja, akuisisi data visual operasional di lantai pabrik, partisi serta augmentasi dataset, prapemrosesan citra, anotasi data koordinat spasial, hingga pelatihan arsitektur jaringan saraf konvolusional YOLOv5 serta penerapan sistem inferensi interaktif. Langkah awal dimulai dengan mengamati alur kerja perakitan bumper pada stasiun kerja manual di salah satu perusahaan manufaktur komponen otomotif guna memetakan interaksi fisik antara operator dengan komponen mekanik. Observasi lapangan ini bertujuan untuk mengidentifikasi potensi hambatan visual, dinamika pergerakan tangan saat memasang pengait, serta titik kritis terjadinya kelalaian manusia selama siklus perakitan berlangsung. Kamera inspeksi digital beresolusi tinggi ditempatkan pada kedudukan kaku dengan sudut pandang tegak lurus mengarah ke area kerja pemasangan klip bumper agar bidang pandang tetap stabil terhadap getaran konveyor. Posisi kamera dikalibrasi secara cermat agar mencakup area pengamatan klip besi sisi kiri (klip_lh) dan klip plastik biru sisi kanan (klip_rh) secara simultan tanpa menghalangi ruang gerak tangan operator. Pengaturan lingkungan uji (testbed) diperkuat dengan integrasi modul pencahayaan berbasis cincin iluminasi (ring illumination) yang dipasang simetris melingkari sensor kamera untuk mereduksi bayangan pekat di sekitar kedudukan komponen. Pengendalian sudut datang cahaya dan pemantauan nilai intensitas iluminasi secara konstan menjadi faktor penentu dalam menjaga kestabilan ekstraksi fitur visual, mengingat permukaan panel bumper berbahan polimer cenderung menghasilkan pantulan spekulat saat terpapar fluktuasi lampu pabrik. Setelah parameter perangkat keras terpasang kokoh, sinkronisasi laju transmisi data dilakukan antara modul kamera dengan unit komputasi tepi (edge computing) agar akuisisi bingkai citra berjalan tanpa latensi. Penataan instrumen secara terkalibrasi ini memastikan setiap pergerakan komponen terbingkai dengan rasio aspek yang konsisten sebelum diproses ke tahapan prapemrosesan dan pemodelan deteksi

objek. Standardisasi penataan fisik dan pencahayaan terkendali ini sekaligus berfungsi meminimalkan gangguan derau visual dari latar belakang dinamis pabrik sehingga integritas data citra tetap terjaga sepanjang proses pengujian. Rangkaian tahapan rancang bangun penelitian ini dipaparkan secara terstruktur melalui diagram alur kerja komprehensif pada Gambar 1.



Gambar 1. Alur Penelitian

Berdasarkan skema tahapan penelitian pada Gambar 1, proses diawali dengan pengumpulan dataset visual yang representatif terhadap variasi kondisi operasional pabrik. Sebanyak 1.250 citra beresolusi tinggi berhasil diakuisisi secara langsung dari lini produksi, mencakup ragam variasi intensitas pencahayaan antara 250 hingga 750 lux, variasi bayangan tangan pekerja, serta getaran mekanis pada meja kerja. Dataset operasional tersebut kemudian dipartisi ke dalam tiga himpunan data independen dengan rasio pembagian 70:20:10. Alokasi spesifik dari pembagian data tersebut terdiri atas 70% atau sebanyak 875 citra untuk data pelatihan (training set), 20% atau sebanyak 250 citra untuk data validasi (validation set), dan 10% atau sebanyak 125 citra sebagai data pengujian (testing set). Guna meningkatkan ketahanan model terhadap gangguan visual di lantai produksi, teknik augmentasi data diterapkan pada himpunan data latih, meliputi penyesuaian kontras acak, modifikasi kecerahan, pembalikan horizontal (horizontal flip), dan penggabungan mosaik multi-citra (mosaic augmentation).

Tahapan prapemrosesan citra memanfaatkan fungsi pustaka OpenCV dan manipulasi matriks NumPy guna menormalisasi format piksel sebelum dialirkan ke lapisan konvolusi YOLOv5. Transformasi ruang warna dari format Blue-Green-Red (BGR) menjadi Red-Green-Blue (RGB) serta penskalaan nilai intensitas piksel ke rentang nol hingga satu diterapkan secara seragam. Setiap citra selanjutnya dianotasi secara manual dengan menandai koordinat spasial kotak pembatas (bounding box) pada empat kategori kondisi perakitan fisik, yaitu kondisi terpasang normal (OK), klip tidak terpasang (missing), posisi klip miring (misaligned), dan jenis komponen tidak sesuai (wrong part). Model YOLOv5 kemudian dilatih menggunakan bobot awal teroptimasi dan dievaluasi performa identifikasinya secara independen sebelum dideploy ke dalam antarmuka web pemantauan seketika.

2.2 Skenario Pengujian dan Parameter Model

Pelatihan model YOLOv5 dieksekusi menggunakan kerangka kerja PyTorch selama 100 epoch dengan konfigurasi ukuran batch sebesar 16 citra per iterasi. Optimasi gradien bobot model memanfaatkan algoritma Stochastic Gradient Descent dengan momentum 0,937, weight decay 0,0005, serta tingkat laju pembelajaran awal 0,01 yang diturunkan secara dinamis menggunakan penjadwal cosine annealing. Proses pelatihan ini difokuskan untuk mencapai nilai kerugian terendah pada fungsi objektif regresi kotak pembatas (box loss berbasis CIOU), klasifikasi kelas (classification loss), dan pendeteksian keberadaan objek (objectness loss). Pemantauan berkala pada setiap siklus dilakukan guna mencegah terjadinya kondisi jenuh (overfitting) maupun kegagalan asimilasi bobot (underfitting). Seluruh citra distandarisasi ke dimensi matriks seragam guna menjaga stabilitas ekstraksi fitur

spasial tanpa membebani alokasi memori grafis (VRAM). Pengujian performa inferensi komputasi dikonfigurasi secara ketat agar sistem mampu memberikan keputusan verifikasi kualitas secara cepat dan andal. Parameter operasional yang diterapkan pada modul inferensi sistem dirangkum secara rinci pada Tabel 1.

Tabel 1. Parameter Deteksi

Parameter Inferensi Komputasional	Nilai Konfigurasi Terapan	Keterangan Fungsionalitas
Ambang Batas Keyakinan (Confidence Threshold)	0,25	Menyeimbangkan sensitivitas deteksi dan mencegah alarm palsu
Ambang Batas Irisan Objek (IoU Threshold)	0,45	Standar eliminasi duplikasi kotak batas pada objek berdekatan
Batas Maksimum Deteksi Bingkai	300	Batas toleransi alokasi memori grafis pada skenario visual padat
Dimensi Resolusi Citra Masukan	640 x 640 Piksel	Optimalisasi representasi fitur spasial dan kecepatan pemrosesan
Algoritma Penekan Nonmaksimum (NMS)	Greedy NMS Terintegrasi	Menyeleksi kandidat kotak pembatas dengan skor probabilitas tertinggi

Berdasarkan parameter operasional yang tercantum pada Tabel 1, konfigurasi tersebut diterapkan langsung pada peladen backend Flask yang terhubung dengan basis data SQLite. Ambang batas keyakinan 0,25 memastikan bahwa fitur visual yang samar tetap dapat terdeteksi tanpa meloloskan derau latar belakang, sementara ambang batas irisan kotak 0,45 secara efektif mengeliminasi kemunculan kotak deteksi ganda pada satu elemen fisik yang sama. Kinerja deteksi dari algoritma diukur secara kuantitatif menggunakan matriks kebingungan yang memetakan luaran True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Akurasi sistem dihitung melalui perbandingan jumlah total prediksi benar terhadap seluruh populasi sampel uji:

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Presisi mengukur ketepatan prediksi komponen normal yang dihasilkan oleh sistem terhadap kondisi fisik aktual:

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

Recall mencerminkan kepekaan model dalam menemukan dan mengenali seluruh komponen normal yang sebenarnya terpasang di lapangan:

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

Skor F1 dihitung sebagai rata-rata harmonik antara presisi dan recall guna memverifikasi keseimbangan performa model:

$$F1 = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (4)$$

Formulasi matematis tersebut digunakan sebagai dasar evaluasi obyektif dalam menguji keandalan sistem saat beroperasi secara penuh di lingkungan perakitan pabrik.

3. HASIL DAN PEMBAHASAN

3.1 Analisis Kurva Konvergensi Pelatihan

Tahap pelatihan model kecerdasan buatan merupakan indikator sentral untuk menentukan apakah arsitektur YOLOv5 mampu menyerap representasi visual dari komponen otomotif secara optimal tanpa mengalami penghafalan data berlebihan (overfitting) atau kegagalan asimilasi (underfitting). Proses pelatihan dieksekusi menggunakan perangkat keras pemrosesan grafis komersial selama 100 siklus putaran (epochs) dengan nilai laju pembelajaran awal yang diatur untuk perlahan menurun (cosine annealing). Optimasi bobot gradien diperkuat melalui penerapan algoritma Stochastic Gradient Descent (SGD) guna memastikan stabilitas pembaruan parameter jaringan. Konfigurasi ukuran batch sebesar 16 citra per iterasi diterapkan untuk menjaga efisiensi konsumsi memori grafis selama proses komputasi berlangsung. Pemantauan dilakukan secara komprehensif terhadap tiga fungsi kerugian utama, yaitu kerugian lokalisasi kotak pembatas (box loss), keberadaan target (obj loss), dan akurasi klasifikasi (cls loss). Untuk mengevaluasi keandalan fungsional model, rekam jejak fungsi kerugian diekstraksi dari periode awal hingga titik stabil. Rekapitulasi perbandingan nilai fungsi kerugian pada interval epoch tertentu disajikan secara sistematis pada Tabel 2.

Tabel 2. Analisis Kurva

Fase Siklus (Epoch)	Kerugian Kotak (Box Loss)	Kerugian Objek (Obj Loss)	Kerugian Kelas (Cls Loss)	Status Konvergensi
Epoch 10	0.0845	0.0512	0.0321	Penurunan drastis awal
Epoch 30	0.0412	0.0245	0.0118	Stabilisasi pola matriks
Epoch 60	0.0221	0.0156	0.0045	Penghalusan bobot spasial
Epoch 100 (Final)	0.0143	0.0112	0.0019	Optimalisasi penuh (Konvergen)

Berdasarkan data numerik yang tertuang pada Tabel 2, analisis dinamika perbandingan kerugian menunjukkan trajektori konvergensi yang sangat ideal. Pada fase pembukaan di Epoch 10, seluruh variabel kerugian (box loss, obj loss, dan cls loss) mengalami penurunan eksponensial yang curam dari nilai inisialisasi awal. Fenomena tersebut mengonfirmasi bahwa algoritma dengan cepat membedakan antara fitur klip logam dan latar belakang citra.

Memasuki fase pertengahan siklus pada Epoch 30 hingga Epoch 60 dalam Tabel 2, nilai box loss yang direpresentasikan melalui formulasi Complete Intersection over Union (CIoU) menyusut secara asimtotik dari 0.0412 menjadi 0.0221. Penurunan tersebut mengindikasikan proses penghalusan bobot spasial, di mana model tidak hanya mendeteksi keberadaan objek, melainkan secara presisi mengoreksi proporsi serta orientasi garis tepi kotak pembatas (bounding box) agar memeluk objek klip logam seakurat mungkin.

Pencapaian akhir pada Epoch 100 dalam Tabel 2 mencatatkan tingkat kerugian klasifikasi (cls loss) yang sangat rendah hingga mendekati angka nol mutlak, yaitu 0.0019, serta nilai kerugian objek (obj loss) sebesar 0.0112. Minimnya margin kesalahan dan ketiadaan fluktuasi liar saat divalidasi silang membuktikan efektivitas modul arsitektur backbone CSPDarknet dalam menggeneralisasi representasi visual tanpa mengalami overfitting. Stabilitas penyusutan nilai kerugian pada Tabel 2 menjadi jaminan teknis bahwa model telah mencapai konvergensi penuh dan siap diimplementasikan secara real-time pada sistem inspeksi kamera produksi.

3.2 Kinerja Deteksi dan Evaluasi Matriks Klasifikasi

Implementasi pengujian otomatis diawali dengan validasi visual langsung pada stasiun kerja untuk memastikan model mampu melokalisasi dan mengenali setiap komponen secara waktu nyata (real-time) melalui pembagian area inspeksi terarah, sebagaimana ditampilkan pada Gambar 2.



Gambar 2. Hasil Deteksi

Berdasarkan visualisasi pada Gambar 2, sistem membagi bidang pantau ke dalam dua zona pengawasan utama, yakni Area Klip Besi (Left Hand/LH) di sisi kiri dan Area Klip Biru (Right Hand/RH) di sisi kanan. Pembagian Region of Interest (ROI) tersebut memungkinkan model fokus menginspeksi kelengkapan komponen tanpa terganggu oleh pola tekstur latar belakang kain yang bergaris. Pada zona kiri, kotak pembatas (bounding box) berhasil mengidentifikasi klip besi secara akurat dengan tingkat keyakinan (confidence score) sebesar 99%, yang secara simultan memicu status visual "OK" berwarna kontras.

Kondisi pencahayaan pada Gambar 2 terpantau berada pada nilai intensitas Lux/Brightness 125, sebuah parameter ambang batas yang memadai untuk menangkap kontur fisik klip plastik di sisi kanan serta klip logam di sisi kiri. Kemampuan algoritma dalam mengunci kedua komponen secara serempak membuktikan bahwa filter ekstraksi fitur bekerja efektif meski terdapat potensi pantulan cahaya pada permukaan material benda kerja. Keberhasilan verifikasi visual pada Gambar 2 menjadi landasan operasional sebelum performa klasifikasi dievaluasi secara menyeluruh ke dalam data kuantitatif.

Setelah divalidasi ketangguhannya, jaringan saraf tiruan diuji secara langsung pada kondisi operasional lantai produksi perakitan bumper otomotif guna mengevaluasi parameter ketepatan metrik di bawah beban inferensi nyata. Evaluasi statistik dilakukan melalui matriks konfusi (confusion matrix) terhadap 277 citra yang mencakup beragam variasi konfigurasi perakitan, di mana setiap bingkai diukur tingkat kecocokannya terhadap kondisi fisik aktual di stasiun kerja. Guna membuktikan stabilitas serta konsistensi hasil verifikasi visual tersebut pada skala pengujian yang lebih luas, rekapitulasi data performa sistem identifikasi anomali dirangkum secara komprehensif dalam Tabel 3.

Tabel 3. Rekapitulasi Matriks

Kategori Evaluasi Klasifikasi	Jumlah Insiden Aktual	Deskripsi Fungsional Hasil Inspeksi
Prediksi Positif Benar (True Positive)	244 Kejadian	Sistem berhasil memverifikasi produk rakitan normal (OK)
Prediksi Negatif Benar (True Negative)	29 Kejadian	Sistem secara tepat menahan produk tidak lengkap (NG)
Prediksi Positif Palsu (False Positive)	3 Kejadian	Sistem meloloskan produk cacat akibat gangguan visual
Prediksi Negatif Palsu (False Negative)	1 Kejadian	Sistem memberikan alarm palsu pada produk yang sebenarnya normal
Metrik Akurasi (Accuracy)	98,6%	Tingkat ketepatan deteksi secara komprehensif
Metrik Presisi (Precision)	98,9%	Proporsi keandalan prediksi benda kerja tanpa cacat
Tingkat Sensitivitas (Recall)	99,8%	Kemampuan melacak kembali seluruh target perakitan
Skor Harmonik (F1-Score)	99,3%	Ekuilibrium pembobotan antara akurasi presisi dan recall

Mengacu pada rekapitulasi data pada Tabel 3, model deteksi menunjukkan kinerja yang sangat baik dengan perolehan akurasi keseluruhan sebesar 98,6%. Tingginya frekuensi pada kategori True Positive (244 kejadian) dan True Negative (29 kejadian) pada Tabel 3 membuktikan efektivitas arsitektur PANet (Path Aggregation Network) dalam mereduksi distorsi optik, sehingga sistem mampu membedakan secara tegas antara produk yang terpasang utuh dan komponen yang hilang.

Keandalan sistem didukung oleh nilai Recall sebesar 99,8%, yang merupakan indikator krusial dalam manufaktur berstandar safety-critical untuk memastikan hampir seluruh cacat terdeteksi tanpa ada komponen terlewat. Selain itu, nilai presisi sebesar 98,9% serta F1-Score sebesar 99,3% pada Tabel 3 menunjukkan keseimbangan performa model yang optimal. Hasil pengujian pada Tabel 3 mengonfirmasi bahwa sistem inspeksi berbasis edge computing ini memenuhi kriteria mekanisme Poka-Yoke dengan tingkat kesalahan prediksi yang sangat minim.

3.3 Analisis Kasus Kegagalan Secara Mendalam

Walaupun pencapaian metrik secara keseluruhan menghasilkan level superior, sistem komputasi tidak sepenuhnya terbebas dari kesalahan klasifikasi mikroskopis. Terdapat rincian spesifik mengenai munculnya 3 kejadian prediksi positif palsu (False Positive) dan 1 insiden prediksi negatif palsu (False Negative) yang membutuhkan audit teknis menyeluruh.

Investigasi pertama terhadap penyebab dari tiga kejadian False Positive mengarah pada interferensi optikal yang bersumber dari pantulan spekular (specular reflection). Lingkungan stasiun perakitan didominasi oleh peralatan berbahan baja tahan karat dan material bumper berlapis epoksi mengkilap. Ketika modul pencahayaan memaparkan emisi foton bersudut miring terhadap permukaan krom komponen di atas konveyor, sebagian energi cahaya tersebut dipantulkan secara langsung ke lensa sensor, menciptakan pantulan lensa (lens flare) lokal dengan saturasi tinggi [21]. Dalam struktur konvolusi yang mengekstraksi gradien tepi, kilatan cahaya tajam ini secara tidak disengaja memiliki kepadatan spasial yang menyerupai lekukan klip penahan besi [18]. Konsekuensinya, algoritma mengalami halusinasi fitur, menempatkan kotak pembatas fiktif, dan mengkategorikan wilayah tersebut sebagai klip yang terpasang meskipun kenyataannya absen. Kelemahan bawaan sistem kamera pasif terhadap anomali radiometrik permukaan ini merupakan sebuah tantangan utama dari sistem pemantauan otomotif konvensional [22].

Di sisi lain, satu kasus kejadian False Negative berakar pada dinamika posisi fisik stasiun kerja. Operator yang melakukan tugas secara repetitif sering kali mengubah sudut orientasi benda kerja sepersekian derajat. Pada kejadian tersebut, sudut perakitan bersinggungan dengan sudut pengamatan lensa (camera angle), ditambah dengan oklusi ringan akibat tangan mekanik atau kabel yang menjuntai [23]. Situasi ini menghasilkan efek pembayangan (shadowing) pekat yang sepenuhnya menutupi kontur klip plastik biru ke dalam latar belakang yang gelap. Hilangnya kontras lokal ini menurunkan respons aktivasi jaringan, sehingga objek gagal melewati nilai ambang batas keyakinan deteksi [24]. Solusi komprehensif untuk mitigasi kendala ini mencakup kalibrasi ulang cincin iluminasi dengan filter polarisasi sirkular guna menyaring radiasi cahaya silau, serta pengaturan sudut fiksasi kamera secara zenit parsial untuk mempersempit penampakan bayangan yang terbentuk.

3.4 Komparasi Kinerja Algoritma dan Kecepatan Komputasi

Penilaian terhadap kualitas perangkat lunak pendeteksi tidak cukup hanya diukur dari segi akurasi klasifikasi semata, melainkan juga menuntut verifikasi objektif terkait efisiensi transmisi datanya. Kelambatan respons komputasi (latency) merupakan kendala operasional yang berisiko menumpuk laju ban berjalan dan menghambat sinkronisasi antara manusia dan mesin. Pengujian kecepatan inferensi dan studi komparatif sistem usulan dengan beberapa arsitektur deteksi objek disajikan pada Tabel 4.

Tabel 4. Analisis Komparatif

Arsitektur Detektor	Akurasi Rata-rata (mAP)	Waktu Inferensi per Bingkai	Kapasitas Kecepatan Laju	Ketahanan Resolusi Logam
Model CNN Dua Tahap	92,5%	85,0 ms	11 FPS (Lambat)	Rentan pantulan
Algoritma YOLOv3	89,2%	45,5 ms	22 FPS (Menengah)	Kurang stabil
Model YOLOv7	94,6%	35,0 ms	28 FPS (Cukup)	Menengah
Sistem Usulan (YOLOv5)	98,6%	12,5 ms	65 FPS (Sangat Responsif)	Tangguh dengan Prapemrosesan

Berdasarkan data komparasi pada Tabel 4, sistem usulan berbasis YOLOv5 menunjukkan performa paling unggul dibandingkan arsitektur lainnya, baik dari sisi akurasi maupun efisiensi komputasi. Waktu inferensi pada sistem usulan tercatat hanya 12,5 milidetik per bingkai, yang menghasilkan kecepatan pemrosesan hingga 65 Frames Per Second (FPS) [25]. Kecepatan tersebut melampaui batas minimum real-time standar industri (30 FPS), sehingga tampilan visual inspeksi berjalan lancar tanpa jeda (lagging).

Sebaliknya, data pada Tabel 4 menunjukkan bahwa arsitektur pembanding seperti algoritma YOLOv3 dan model CNN dua tahap menghasilkan waktu inferensi yang jauh lebih lambat, masing-masing sebesar 45,5 ms (22 FPS) dan 85,0 ms (11 FPS). Rendahnya laju transmisi pada model CNN dua tahap dipengaruhi oleh tahapan pembangkitan usulan wilayah (region proposals) yang membutuhkan daya komputasi tinggi [26]. Selain itu, perolehan mean Average Precision (mAP) sistem usulan mencapai 98,6% pada Tabel 4, sekaligus mempertahankan ketahanan deteksi terhadap pantulan permukaan logam berkat integrasi tahapan prapemrosesan citra. Hasil pengujian pada Tabel 4 mengonfirmasi bahwa model YOLOv5 yang diusulkan memenuhi syarat keandalan teknis untuk diintegrasikan ke dalam lini produksi otomatis.

3.5 Analisis Kelalaian Faktor Manusia

Pemanfaatan data jejak rekam anomali berbasis kecerdasan buatan tidak hanya menyajikan utilitas pelacakan kelengkapan komponen, tetapi juga berfungsi sebagai instrumen analitik ergonomi untuk menyingkap dinamika kinerja operator. Integrasi peladen backend Flask dengan basis data SQLite memungkinkan setiap keputusan verifikasi kualitas tercatat secara terperinci bersama penanda waktu (timestamp) yang presisi. Melalui mekanisme pencatatan riwayat otomatis ini, akumulasi kesalahan pemasangan klip dapat ditelusuri kembali guna mengidentifikasi pola kelelahan fisik maupun kognitif pekerja pada stasiun kerja manual. Informasi diagnostik tersebut mengubah data inspeksi visual menjadi wawasan manajerial yang bermanfaat untuk mengevaluasi batas ketahanan tubuh pekerja di lini perakitan. Data log deteksi komponen cacat (Not Good) yang tersimpan di dalam basis data diekstraksi untuk memetakan frekuensi insiden kelalaian manual sepanjang jam operasional kerja, sebagaimana dirangkum pada Tabel 5.

Tabel 5. Distribusi Waktu

Waktu Operasional Lini Pabrik	Volume Komponen Tidak Lengkap	Persentase Insiden Keseluruhan	Analisis Ergonomi Pekerja
Pukul 21:00 (Awal Shift)	5 Komponen	16,67%	Tingkat konsentrasi masih prima Puncak kelelahan kognitif dan fisik
Pukul 22:00 (Fase Kritis)	20 Komponen	66,66%	
Pukul 23:00 (Akhir Pemantauan)	5 Komponen	16,67%	Ritme kerja kembali stabil

Berdasarkan data distribusi pada Tabel 5, tercatat lonjakan signifikan volume komponen tidak lengkap pada pukul 22:00, yaitu mencapai 20 insiden atau setara dengan 66,66% dari total temuan cacat. Pola konsentrasi cacat pada satu jam tertentu ini mengindikasikan terjadinya fase kritis akibat kelelahan kognitif dan penurunan fokus operator di tengah pergantian ritme kerja malam.

Sebaliknya, data pada Tabel 5 memperlihatkan bahwa frekuensi kesalahan pada pukul 21:00 dan 23:00 berada pada angka yang jauh lebih rendah, masing-masing hanya sebesar 16,67% (5 komponen). Temuan empiris pada Tabel 5 memberikan bukti kuantitatif yang bernilai strategis bagi manajemen produksi dalam menyusun intervensi ergonomis, seperti penjadwalan rotasi tugas atau pemberian jeda istirahat singkat terarah menjelang pukul 22:00 guna menekan laju kesalahan perakitan manual secara preventif.

3.6 Pembahasan

Peralihan dari era pengawasan inspeksi visual konvensional menuju teknologi pemantauan otonom (Automated Visual Inspection) menginisiasi lonjakan paradigma efisiensi biaya serta pengembalian investasi yang transformatif bagi sektor manufaktur otomotif [6], [13]. Integrasi kamera cerdas pada lini produksi secara langsung menekan pengeluaran operasional melalui pengurangan beban kerja inspeksi manual sekaligus meminimalkan rasio produk gagal (scrap reduction) melalui peringatan dini sebelum komponen diproses ke lini lanjutan [2], [27]. Kebaruan ilmiah (novelty) dari penelitian ini terletak pada integrasi terstruktur antara algoritma deep learning dan modul analisis kelainan (fatigue analytics) dalam satu kerangka kerja web berbasis Flask. Berbeda dengan mayoritas riset terdahulu yang hanya berfokus pada hasil klasifikasi biner untuk menentukan status cacat secara pasif, sistem ini bertransformasi menjadi instrumen diagnostik ergonomi kerja yang interaktif guna memetakan dinamika penurunan konsentrasi pekerja (human error) di stasiun perakitan secara aktual.

Validitas kinerja sistem usulan dinilai lebih lanjut melalui komparasi langsung dengan berbagai studi literatur terdahulu berdasarkan karakteristik objek, waktu inferensi, dan metrik akurasi [1], [10]. Penelitian terdahulu yang menguji inspeksi komponen otomotif berbasis CNN standar hanya menghasilkan tingkat akurasi 91,0% dengan waktu respons yang lambat hingga 1 detik, sedangkan penerapan CNN pada pengujian weld nut membutuhkan waktu respons sekitar 0,14 detik [19]. Di samping itu, penerapan arsitektur YOLOv4 pada inspeksi sejenis tercatat hanya mencapai akurasi deteksi sebesar 94,6% [28], sementara model YOLOv7 dan YOLOv8 rentan mengalami penurunan laju bingkai citra (lag) serta alarm palsu akibat pantulan cahaya permukaan logam [14], [15], [17]. Melalui pengujian lapangan pada 277 siklus inspeksi child part assembly bumper, sistem berbasis YOLOv5 yang dikembangkan ini berhasil melampaui batasan penelitian terdahulu dengan capaian akurasi 98,6%, waktu inferensi 12,5 milidetik, kecepatan pemrosesan 65 FPS, serta kepekaan recall 99,8%. Integrasi prapemrosesan OpenCV terbukti tangguh mengatasi gangguan optik dan membuktikan bahwa sistem manufaktur cerdas ini siap beroperasi sebagai mekanisme Poka-Yoke digital yang andal di lantai produksi. Pencapaian performa tersebut mempertegas efektivitas arsitektur model dalam mencegah kelolosan produk cacat secara real-time sebelum memasuki tahap perakitan lanjutan. Dengan demikian, solusi otomasi ini tidak hanya mengoptimalkan efisiensi kendali mutu, melainkan juga menekan biaya operasional akibat pengerjaan ulang komponen secara berkelanjutan.

4. KESIMPULAN

Penelitian penerapan algoritma YOLOv5 berbasis visi komputer ini membuktikan keberhasilan perancangan, implementasi, serta evaluasi sistem pemantauan child part assembly secara waktu nyata di lingkungan industri manufaktur otomotif dengan performa yang sangat andal. Integrasi rekayasa fungsi prapemrosesan citra dengan arsitektur jaringan deteksi objek terbukti tangguh dalam menormalisasi gangguan fluktuasi pencahayaan buatan dan derau pabrik, menghasilkan tingkat akurasi deteksi komponen secara keseluruhan sebesar 98,6 persen, presisi 98,9 persen, kapabilitas recall 99,8 persen, serta skor ekuilibrium F1-score di angka 99,3 persen. Stabilitas metrik analitik visual ini berpadu dengan efisiensi komputasi berkecepatan inferensi 12,5 milidetik, menjamin kelancaran aliran video pemantauan pada antarmuka operasional hingga 65 bingkai per detik tanpa hambatan kelambatan. Identifikasi kasus kegagalan klasifikasi berhasil mengungkap sensitivitas sensor terhadap pantulan spekular, sekaligus menjadi landasan pengembangan fitur fatigue analytics yang secara presisi mendeteksi lonjakan kelainan pekerja pada pukul 22:00 malam akibat kelelahan fisik dan kognitif. Kontribusi ilmiah dan praktis penelitian ini terwujud dalam sebuah kerangka kerja pemantauan terpadu yang memadukan keunggulan model deteksi ringan YOLOv5 dengan instrumen diagnostik penurunan konsentrasi pekerja secara aktual di lantai pabrik. Sebagai saran pengembangan masa depan, integrasi perangkat keras industri seperti modul Programmable Logic Controller (PLC) dan aktuator pneumatik direkomendasikan secara ringkas guna menghentikan conveyor secara otomatis saat anomali terdeteksi. Secara praktis bagi industri otomotif secara umum, implementasi kerangka kerja ini memberikan jaminan standarisasi mutu Zero Defect melalui mekanisme Poka-Yoke digital yang menekan pemborosan material sisa serta mereduksi biaya pengerjaan ulang secara signifikan. Selain itu, adopsi teknologi cerdas terpadu ini menjadi rujukan strategis dalam mendorong transformasi lini perakitan konvensional menuju ekosistem pabrik cerdas yang mandiri, adaptif, dan berdaya saing tinggi.

5. PERNYATAAN PENULIS

5.1 Kontribusi Penulis

Konseptualisasi: Abby Muhammad Titan, Dendy K. Pramudito, dan Muhamad Fatchan;

Metodologi: Abby Muhammad Titan, Dendy K. Pramudito, dan Muhamad Fatchan;

Perangkat Lunak: Abby Muhammad Titan;

Validasi: Abby Muhammad Titan, Dendy K. Pramudito, dan Muhamad Fatchan;

Analisis Formal: Abby Muhammad Titan dan Muhamad Fatchan;

Investigasi: Abby Muhammad Titan;



Sumber Daya: Dendy K. Pramudito dan Muhamad Fatchan;
Kurasi Data: Abby Muhammad Titan;
Penulisan Draf Awal: Abby Muhammad Titan;
Penulisan, Peninjauan, dan Penyuntingan: Abby Muhammad Titan, Dendy K. Pramudito, dan Muhamad Fatchan;
Visualisasi: Abby Muhammad Titan;
Pengawasan: Dendy K. Pramudito dan Muhamad Fatchan.
Seluruh penulis telah membaca dan menyetujui versi manuskrip yang telah diterbitkan.

5.2 Ketersediaan Data

Data yang disajikan dalam penelitian ini tersedia berdasarkan permintaan kepada penulis korespondensi.

5.3 Pendanaan

Penelitian ini tidak menerima pendanaan eksternal.

REFERENCES

- [1] J. P. Yun, W. C. Shin, G. Koo, M. S. Kim, C. Lee, and S. J. Lee, "Automated defect inspection system for metal surfaces based on deep learning and data augmentation," *J. Manuf. Syst.*, vol. 55, pp. 317–324, 2020, doi: 10.1016/j.jmsy.2020.03.009.
- [2] P. Peças, "Industry 5.0 Challenges for Manufacturing Systems: Evidence Mapping and Research Agenda," *Sustainability*, vol. 18, no. 7, p. 3323, 2026, doi: 10.3390/su18073323.
- [3] M. Peruzzini, E. Prati, and M. Pellicciari, "A framework to design smart manufacturing systems for Industry 5.0 based on the human-automation symbiosis," *Int. J. Comput. Integr. Manuf.*, 2024, doi: 10.1080/0951192X.2023.2257634.
- [4] D. G. Marangon *et al.*, "A fast and robust quantum random number generator with a self-contained integrated photonic randomness core," *Nat. Electron.*, vol. 7, no. 5, pp. 396–404, 2024, doi: 10.1038/s41928-024-01140-0.
- [5] A. Kaleli, "Development of Advanced Automation Systems for Industry 5.0," in *Business Challenges and Opportunities in the Era of Industry 5.0*, S. Grima, S. S. Kaleli, M. Baygin, and E. Boztepe, Eds., Emerald Publishing Limited, 2025, doi: 10.1108/978-1-83549-676-320251006.
- [6] M. Javaid, A. Haleem, R. P. Singh, and R. Suman, "Significance of Quality 4.0 towards comprehensive enhancement in manufacturing sector," *Sensors Int.*, vol. 2, p. 100109, 2021, doi: 10.1016/j.sintl.2021.100109.
- [7] L. He, X. Ren, Q. Gao, X. Zhao, B. Yao, and Y. Chao, "The connected-component labeling problem: A review of state-of-the-art algorithms," *Pattern Recognit.*, vol. 70, pp. 25–43, 2017, doi: 10.1016/j.patcog.2017.04.018.
- [8] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, pp. 779–788, doi: 10.1109/CVPR.2016.91.
- [9] S. X. Tan, J. Y. Ong, M. K. O. Goh, and C. Tee, "Boosting Vehicle Classification with Augmentation Techniques across Multiple (YOLO) Versions," *Int. J. Informatics Vis.*, vol. 8, no. 1, pp. 45–54, 2024, doi: 10.62527/ijov.8.1.2313.
- [10] M. K. Ferguson, A. Ronay, Y.-T. T. Lee, and K. H. Law, "Detection and segmentation of manufacturing defects with convolutional neural networks and transfer learning," *Smart Sustain. Manuf. Syst.*, vol. 2, no. 1, pp. 137–164, 2018, doi: 10.1520/SSMS20180033.
- [11] X. Wang and Y. Bi, "A Real-Time Textile Defect Inspection System for Industrial Polyester Reinforcement Layers Based on YOLO and PLC-Driven Closed-Loop Control," *IEEE Access*, vol. 14, pp. 33873–33889, 2026, doi: 10.1109/ACCESS.2026.3669364.
- [12] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, 3rd ed. Upper Saddle River, NJ: Pearson Prentice Hall, 2008.
- [13] X. Zheng, S. Zheng, Y. Kong, and J. Chen, "Recent advances in surface defect inspection of industrial products using deep learning techniques," *Int. J. Adv. Manuf. Technol.*, vol. 113, pp. 35–58, 2021, doi: 10.1007/s00170-021-06592-8.
- [14] J. Chen, S. Bai, G. Wan, and Y. Li, "Research on (YOLOv7)-based defect detection method for automotive running lights," *Syst. Sci. & Control Eng.*, vol. 11, no. 1, p. 2185916, 2023, doi: 10.1080/21642583.2023.2185916.
- [15] Y. Wang, B. Guo, L. Sun, and R. Yu, "Toward Real-Time Industrial Small Object Inspection: Decoupled Attention and Multi-Scale Aggregation for (PCB) Defect Detection," *Electronics*, vol. 15, no. 6, p. 1191, 2026, doi: 10.3390/electronics15061191.
- [16] M. Mehta, "(AFF-YOLO): A Real-Time Industrial Defect Detection Method Based on Attention Mechanism and Feature Fusion," 2023, doi: 10.21203/rs.3.rs-3449230/v1.
- [17] Y. He, B. Wu, J. Mao, W. Jiang, J. Fu, and S. Hu, "An effective MID-based visual defect detection method for specular car body surface," *J. Manuf. Syst.*, vol. 72, pp. 154–162, 2024, doi: <https://doi.org/10.1016/j.jmsy.2023.11.014>.
- [18] X. Peng and H. Li, "Automated detection of damage precursors on specular surfaces using an enhanced deep-learning framework," *Appl. Opt.*, vol. 65, no. 15, pp. 5039–5052, May 2026, doi: 10.1364/AO.590533.
- [19] K. J. Lee, J. W. Kwon, S. Min, and J. Yoon, "Embedding Convolution Neural Network-Based Defect Finder for Deployed Vision Inspector in Manufacturing Company {Frontec}," in *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, pp. 13164–13171, doi: 10.1609/aaai.v34i08.7020.
- [20] J. Shi, J. Yang, and Y. Zhang, "Research on steel surface defect detection based on {YOLOv5} with attention mechanism," *Electronics*, vol. 11, no. 22, p. 3735, 2022, doi: 10.3390/electronics11223735.
- [21] J. Zhang, "Line-Focused Laser and {YOLOv5}-Based High-Precision Defect Detection for Reflective Surfaces," *Informatica*, vol. 49, no. 13, pp. 385–396, 2025, doi: 10.31449/inf.v49i13.7556.
- [22] H.-D. Lin, S.-Y. Li, and C.-H. Lin, "An Automated Vision-Based Inspection System for Metallic Lock Surface Defects Using a Transformer-Enhanced U-Net," *Sensors*, vol. 26, no. 9, 2026, doi: 10.3390/s26092608.



- [23] A. Alzarooni, E. Iqbal, S. U. Khan, S. Javed, B. Moyo, and Y. Abdulrahman, “Anomaly Detection for Industrial Applications, Its Challenges, Solutions, and Future Directions: A Review,” *arXiv Prepr. arXiv2501.11310*, 2025, [Online]. Available: <https://arxiv.org/abs/2501.11310>
- [24] R. vom Schemm, “Aircraft Dent Detection Utilizing Specular Reflections and Deep Learning,” University of Hamburg, Hamburg, Germany, 2025.
- [25] E. A. Saputa, M. Martdiansyah, M. A. Indrajaya, M. D. B. Aristo, A. I. N. K. Kadir, and Alricha, “Performance of {YOLOv5} Object Detection for Waste Type Classification: A Case Study on Domestic Inorganic Waste,” in *Proceedings of the 3rd International Conference on Science in Engineering and Technology (ICoSIET 2024)*, in Advances in Engineering Research, vol. 265. Atlantis Press, 2025, pp. 88–102. doi: 10.2991/978-94-6463-768-7_11.
- [26] C. Chen, B. Wu, and Y. Shi, “An Improved {YOLOv5} Algorithm for Detecting Target,” *IAENG Int. J. Comput. Sci.*, vol. 51, no. 10, pp. 1454–1461, 2024, [Online]. Available: https://www.iaeng.org/IJCS/issues_v51/issue_10/IJCS_51_10_05.pdf
- [27] D. Romero, P. Gaiardelli, D. J. Powell, and M. Zanchi, “Intelligent Poka-Yokes: Error-Proofing and Continuous Improvement in the Digital Lean Manufacturing World,” in *Advances in Production Management Systems. Smart Manufacturing and Logistics Systems: Turning Ideas into Action*, D. Y. Kim, G. von Cieminski, and D. Romero, Eds., Cham: Springer Nature Switzerland, 2022, pp. 595–603.
- [28] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, “{YOLOv4}: Optimal Speed and Accuracy of Object Detection,” *arXiv Prepr. arXiv2004.10934*, 2020, doi: 10.48550/arXiv.2004.10934.