



Deteksi Otomatis Peralatan Perawatan dan Instrumen Pesawat Udara di Lingkungan Pendidikan Penerbangan Berbasis YOLO11

Donna N. M. Sirait^{1*}, Nurmahendra Harahap², Muhammad Amril³, Suherman⁴

^{1,3,4} Program Studi Teknik Telekomunikasi dan Navigasi Udara, Politeknik Penerbangan Medan, Medan, Indonesia

²Program Studi Teknik Elektro, Fakultas Sains dan Teknologi, Universitas Tjut Nyak Dhien, Medan, Indonesia

^{1*}dehijo@gmail.com, ²nurmahendrasahap@gmail.com, ³m.amrilsiregar@gmail.com,

⁴suherman15051996@gmail.com

*) dehijo@gmail.com

Abstrak-Penelitian ini bertujuan mengembangkan sistem pengenalan otomatis peralatan perawatan dan instrumen pesawat udara berbasis YOLO11 pada lingkungan pendidikan penerbangan. Dataset dikumpulkan dari laboratorium Avionic dan mencakup lima kelas objek, yaitu Airspeed Indicator, Flight Director, Pictorial Navigation Instrument, Crimping GMT 208, dan Crimping GMT 221. Model dilatih secara bertahap melalui tiga iterasi dengan augmentasi data dan dievaluasi menggunakan precision, recall, mAP50, mAP50-95, confusion matrix, serta pengujian live video. Hasil terbaik diperoleh pada iterasi ketiga dengan nilai mAP50-95 sebesar 0,85082, precision 0,96013, recall 0,99207, dan mAP50 0,97450. Pengujian real-time menunjukkan sistem bekerja sangat baik pada kondisi normal, namun performanya menurun ketika terdapat gangguan visual. Confusion matrix menunjukkan bahwa model masih paling sering tertukar pada dua kelas alat crimping yang memiliki kemiripan bentuk. Secara keseluruhan, YOLO11 berpotensi digunakan sebagai alat bantu pembelajaran vokasi penerbangan yang efektif dan adaptif.

Kata Kunci: YOLO11, deteksi objek, peralatan perawatan pesawat, instrumen pesawat udara, pendidikan penerbangan

Abstract-This study aims to develop an automatic recognition system for aircraft maintenance tools and flight instruments using the YOLO11 model in an aviation education environment. The dataset was collected from the Avionic Laboratory and consisted of five object classes: Airspeed Indicator, Flight Director, Pictorial Navigation Instrument, Crimping GMT 208, and Crimping GMT 221. The model was trained iteratively through three stages using data augmentation techniques and evaluated using precision, recall, mAP50, mAP50-95, confusion matrix analysis, and live video testing. The best performance was achieved in the third iteration with an mAP50-95 value of 0.85082, precision of 0.96013, recall of 0.99207, and mAP50 of 0.97450. Real-time testing demonstrated that the system performed very well under normal conditions; however, its performance decreased when visual disturbances were introduced. The confusion matrix analysis showed that the model most frequently confused the two crimping tool classes due to their similar visual characteristics. Overall, the results indicate that YOLO11 has strong potential to be implemented as an effective and adaptive learning support tool in aviation vocational education.

Keywords: YOLO11, object detection, aircraft maintenance tools, aircraft instruments, aviation education

1. PENDAHULUAN

Industri penerbangan menuntut standar keselamatan dan efisiensi yang sangat tinggi, karena kesalahan sekecil apapun dalam pemeliharaan dapat berdampak fatal. Pengelolaan peralatan perawatan dan instrumen pesawat menjadi elemen krusial dalam proses ini. Misalnya, Laporan ATSB menunjukkan bahwa “tool control is an important part of maintenance processes, even for seemingly insignificant components” – meninggalkan bagian alat kecil di dalam mesin pernah menyebabkan kegagalan mesin pesawat[1]. Kondisi inilah yang mendorong pengembangan solusi inovatif. Seiring dengan gelombang Industry 4.0, pemanfaatan kecerdasan buatan, khususnya computer vision, menjadi kunci untuk meningkatkan otomatisasi dan ketelitian inspeksi industri[2]. Berbagai penelitian menegaskan peran penting AI dalam pendidikan vokasi; Zhang et al. (2024) melaporkan bahwa penerapan analisis pembelajaran berbasis AI meningkatkan tingkat kelulusan keterampilan hingga 22,7% dan menekan biaya pelatihan tinggi melalui simulasi virtual hingga 89,6%[3]. Dengan demikian, mengintegrasikan teknologi cerdas ke dalam pendidikan pemeliharaan penerbangan berpotensi mempersempit kesenjangan keterampilan sekaligus meningkatkan keselamatan.





Deteksi objek otomatis menggunakan pembelajaran mendalam telah menjadi fokus penelitian intensif selama lima tahun terakhir[4][5]. Model YOLO (You Only Look Once) merupakan pendekatan satu tahap (*one-stage*) yang memproses gambar keseluruhan dalam satu kali forward pass, menjadikannya sangat cepat dibandingkan detektor dua tahap tradisional[5]. Pada dekade terakhir, seri YOLO telah berkembang dari YOLOv1 hingga versi terbaru, masing-masing memperkenalkan peningkatan arsitektur dan teknik pelatihan. Misalnya, YOLOv3 memperkenalkan backbone Darknet-53 dan prediksi multi-skala untuk objek kecil, YOLOv4 memanfaatkan CSPNet dan augmentasi mosaic untuk performa lebih tinggi, dan versi modern (v5–v8) mengadopsi model yang lebih ringan, optimasi baru, dan dukungan pipeline PyTorch yang mudah digunakan[6]. Sebagai hasilnya, model-model terbaru seperti YOLOv8 menunjukkan akurasi lebih tinggi dan performa waktu nyata yang unggul pada benchmark standar[6].

Berbagai studi telah mengaplikasikan YOLO dalam konteks industri dan pendidikan. Misalnya, Pati et al. (2026) menguji YOLOv3 hingga YOLOv8 untuk deteksi cacat las pada dataset spesifik industri, menemukan bahwa YOLOv8 memberikan peningkatan akurasi deteksi secara signifikan[5]. Ali et al. (2022) menggunakan YOLOv5 untuk memantau kepatuhan penggunaan Alat Pelindung Diri (APD) di laboratorium pendidikan, mencapai *mAP* di atas 0.77 pada deteksi real-time[7]. Zendehele et al. (2023) menerapkan YOLOv5 untuk deteksi berbagai jenis alat di lingkungan manufaktur pintar dan mencapai *mAP* 98.3% dengan presisi tinggi[2]. Teknik serupa juga digunakan untuk pengawasan keselamatan: misalnya, kombinasi YOLOv5 dan YOLOv7 berhasil mendeteksi kelengkapan keselamatan (*safety*) di laboratorium pendidikan[7]. Terdapat pula penelitian yang mengadaptasi YOLOv4 untuk menemukan cacat pada alat berputar dengan *recall* 98,7%[8].

Dalam domain penerbangan, meskipun lebih sedikit, terdapat usaha penerapan YOLO untuk tugas spesifik. Lu et al. (2024) mengembangkan model YOLOv5 yang disempurnakan dengan deformable convolution dan mekanisme atensi untuk mendeteksi tailhook (pengait pesawat) dengan akurasi tinggi[9]. He et al. (2025) memperkenalkan DT-YOLO, yang menggabungkan modul transformer dan deformable convolution pada YOLOv5, untuk mendeteksi komponen pesawat dan personel di apron bandara, meningkatkan *mAP* hingga +2.6 poin pada dataset khusus[10]. Wen et al. (2024) memodifikasi YOLOv8 (LESM-YOLO) untuk deteksi kerusakan saluran pesawat, mencapai *mAP* 96.3% (kenaikan 5.4% dari model dasar)[11]. Sebagai tambahan, penelitian terkait AR (*augmented reality*) untuk pelatihan dan instruksi menunjukkan potensi teknologi visual dalam pendidikan teknis. Morales-Méndez dan del Cerro (2024) mereview penggunaan AR dalam pelatihan industri 4.0, menyoroti tren penggunaan AR untuk menciptakan lingkungan pelatihan yang lebih visual dan imersif[12]. Kwon et al. (2021) mengembangkan konten pelatihan berbasis AR untuk perawatan kereta api, yang secara signifikan meningkatkan efisiensi pelatihan dibandingkan manual cetak[13]. Ini menunjukkan bahwa pendekatan teknologi canggih (YOLO dan/atau AR) dapat berdampak positif dalam skenario pembelajaran praktis.

Adapun Gap dalam penelitian ini adalah belum ada sistem deteksi otomatis yang ditujukan khusus untuk peralatan perawatan pesawat di lingkungan pelatihan penerbangan. Studi terdahulu umumnya fokus pada alat umum industri, PPE, atau komponen tertentu (mis. tailhook)[2][9]. Dengan memfokuskan pada lima kategori objek (tiga jenis instrumen dan dua jenis peralatan umum), sistem ini dirancang untuk mengenali objek dari gambar dengan beragam sudut pengambilan dalam kondisi nyata dengan gangguan visual[11]. Kombinasi teknologi AR dengan deteksi visual dalam pelatihan perawatan pesawat masih jarang dipelajari, meski AR telah terbukti meningkatkan efektivitas pelatihan[12]. Secara khusus, gap penelitian ini adalah penggunaan model YOLO untuk klasifikasi alat perawatan pesawat yang robust dalam beberapa kondisi pencahayaan atau gangguan.

Penelitian ini bertujuan mengembangkan dan mengimplementasikan model Yolo11 untuk pengenalan otomatis peralatan perawatan di lingkungan pendidikan penerbangan. Pendekatan yang diusulkan memanfaatkan arsitektur single-stage YOLO yang dikenal untuk kinerja *real-time* dan akurasi klasifikasi serta deteksi tinggi[14]. Pemilihan Yolo11 dalam penelitian ini disebabkan Yolo11 dilaporkan memiliki performa yang lebih baik daripada YOLO dibawah versi 11,[15]. Tujuan spesifik antara lain: (a) mengumpulkan dan mengannotasi dataset gambar alat perawatan pesawat; (b) membangun arsitektur Yolo11 dengan pelatihan khusus pada dataset tersebut; (c) mengevaluasi performa model dalam kondisi laboratorium dan live gangguan penuh video. Intervensi yang akan dilakukan adalah implementasi berbasis Yolo11 yang memberikan umpan balik visual instan tentang identitas alat; hal ini selaras dengan kebutuhan pembelajaran *task-oriented* dalam pendidikan vokasi. Dengan demikian, penelitian ini diharapkan menjadi langkah konkret dalam penerapan AI untuk pendidikan penerbangan yang lebih aman dan adaptif, sekaligus menyumbang pengetahuan teoretis dan praktis mengenai pemanfaatan model-model deteksi objek mutakhir seperti Yolo11. Dengan konsep ini, penelitian diharapkan memberikan manfaat signifikan bagi mitra (Politeknik Penerbangan) dan masyarakat luas. Bagi taruna, penggunaan aplikasi deteksi berbasis CV akan mempermudah proses belajar peralatan praktis sehingga pemahaman menjadi lebih mendalam. Bagi lembaga pendidikan dan industri, sistem ini dapat meningkatkan efisiensi pelatihan serta mengurangi kesalahan pengenalan peralatan yang berpotensi berujung pada insiden penerbangan.



2. METODOLOGI PENELITIAN

2.1 Rancangan Penelitian

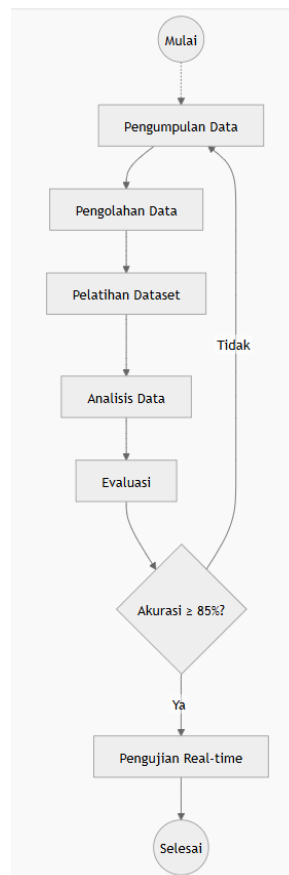
Penelitian ini menggunakan pendekatan *experimental development* untuk mengembangkan dan menguji sistem pengenalan otomatis peralatan perawatan dan instrumen pesawat udara berbasis *You Only Look Once version 11* (Yolo11). Pendekatan ini dipilih karena tujuan riset bukan hanya menghasilkan model deteksi objek, tetapi juga membuktikan kelayakannya sebagai alat bantu pembelajaran di lingkungan pendidikan penerbangan. Secara konseptual, YOLO merupakan detektor objek satu tahap (*one-stage detector*) yang memproses citra secara langsung untuk memprediksi kelas objek dan koordinat *bounding box* dalam satu alur inferensi, sehingga sesuai untuk aplikasi deteksi cepat dan *real-time* [16].

Penelitian dilaksanakan di laboratorium Avionic Politeknik Penerbangan Medan, Kota Medan, Sumatera Utara. Lingkungan laboratorium dipilih karena merepresentasikan konteks penggunaan objek secara nyata dalam pembelajaran taruna, sekaligus memungkinkan proses pengambilan data dilakukan secara terkontrol.

Sebelum sistem dikembangkan, proses pengenalan peralatan perawatan dan instrumen pesawat udara masih bergantung pada identifikasi manual oleh taruna. Dengan penelitian ini diharapkan adanya alat bantu yang akurat dan efisien untuk mendukung pembelajaran di tengah tuntutan teknologi industri 4.0.

2.2 Tahapan Penelitian

Penelitian ini terdiri dari beberapa tahapan penelitian, seperti yang ditampilkan pada Gambar 1.



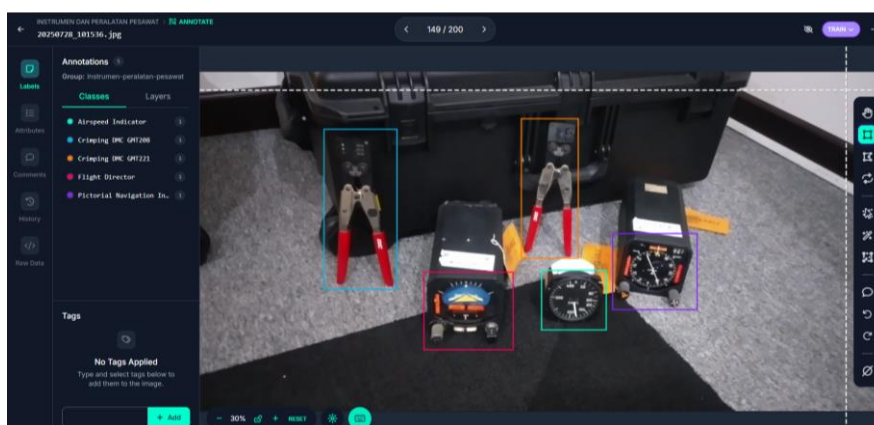
Gambar 1. Tahapan-tahapan Penelitian

Teknik pengumpulan data dilakukan melalui pengambilan citra objek secara langsung di lingkungan laboratorium Avionic. Sampel dipilih secara terarah (*purposive sampling*) berdasarkan relevansi objek terhadap kebutuhan pembelajaran, yaitu lima kelas objek yang terdiri atas tiga instrumen pesawat udara: *Airspeed Indicator*, *Flight Director*, dan *Pictorial Navigation Instrument*; serta dua peralatan perawatan, yaitu *Crimping GMT 221* dan *Crimping GMT 208*. Pengambilan citra dilakukan dari beberapa sudut pandang dan kondisi pencahayaan yang

berbeda agar data lebih representatif terhadap situasi penggunaan nyata. Selain itu, pengujian sistem juga dilakukan menggunakan live video untuk melihat performa model saat dioperasikan secara langsung.

Validitas data dijaga melalui pemilihan objek yang memang digunakan dalam konteks pendidikan avionic, sehingga isi dataset selaras dengan kebutuhan pembelajaran. Validitas representatif juga diperkuat dengan variasi sudut, jarak, dan pencahayaan saat pengambilan gambar. Reliabilitas alat pengumpulan data dijaga dengan prosedur pengambilan citra yang seragam, penggunaan perangkat kamera yang konsisten, serta anotasi yang distandardisasi ke format YOLO melalui *Roboflow*. Dalam konteks artikel, langkah ini penting agar hasil pelatihan tidak dipengaruhi oleh ketidak konsistenan label atau variasi teknis yang tidak terkontrol. Praktik ini sejalan dengan penelitian terkini yang menekankan pentingnya diversifikasi data dan kestabilan anotasi untuk meningkatkan akurasi deteksi objek berbasis YOLO.

Seluruh citra yang terkumpul kemudian melalui tahap praproses. Berdasarkan laporan, citra diseragamkan ukurannya menjadi 640×640 piksel agar sesuai dengan kebutuhan masukan model. Setelah itu dilakukan anotasi objek menggunakan *bounding box* dan label kelas pada *Roboflow* seperti yang ditampilkan pada Gambar 2. Untuk memperkaya data latih, diterapkan pula augmentasi data berupa variasi data dengan melakukan *flip*:horizontal dan vertical, *crop* dari 0% sampai 21%, *shear* 10^0 Horizontal dan 10^0 Vertikal, kemudian kecerahan antara -19% sampai +19%. Pendekatan augmentasi semacam ini sejalan dengan publikasi terkini yang menunjukkan bahwa perluasan data melalui transformasi multi-skala dan perubahan kondisi visual dapat meningkatkan kestabilan serta ketepatan deteksi pada model YOLO [17].



Gambar 2. Proses pelabelan data di RoboFlow

Model utama yang digunakan adalah Yolo11, yang dilatih secara iteratif pada platform berbasis cloud. Pelatihan dilakukan menggunakan Google Colab Pro+ dengan GPU A100 dan *framework* Pytorch sementara untuk data anotasi menggunakan *Roboflow*. Proses pelatihan dilakukan dalam beberapa kali iterasi penambahan data dan pelatihan ulang. Pendekatan evaluasi iterasi berulang dibutuhkan hingga model mencapai akurasi yang diinginkan. Hal ini konsisten dengan penelitian Yolo11 terkini yang menilai kualitas model melalui precision, recall, mAP@0.5, dan mAP@0.5:0.95 untuk mengukur ketepatan klasifikasi sekaligus kualitas lokalisasi objek.

Analisis data dilakukan secara kuantitatif dengan menggunakan metrik evaluasi deteksi objek, yaitu precision, recall, mAP@0.5, mAP@0.5:0.95 dan *confusion matrix*. Kinerja model diuji tidak hanya pada data validasi, tetapi juga pada pengujian langsung melalui *live video* untuk melihat kemampuan model dalam kondisi nyata. Pengujian lanjutan juga dilakukan pada kondisi dengan gangguan visual guna menilai ketahanan (*robustness*) model. Pendekatan ini sejalan dengan praktik evaluasi modern pada penelitian Yolo11 yang menekankan penggunaan mAP@0.5 dan mAP@0.5:0.95 sebagai ukuran utama performa deteksi, karena kedua metrik tersebut menilai akurasi klasifikasi sekaligus ketepatan posisi *bounding box* pada berbagai ambang *Intersection over Union* (IoU).

Hasil yang dari penelitian ini adalah tersedianya sistem pengenalan otomatis yang dapat digunakan sebagai alat bantu pembelajaran bagi taruna Politeknik Penerbangan Medan, mampu mengenali lima objek target secara cepat pada video langsung, dan mencapai kriteria keberhasilan minimum sebesar 85%. Terakhir dilakukan pengujian untuk melihat performa sistem secara *real-time*. Pada bagian ini sistem diuji secara langsung dengan memberikan penghalang transparan pada objek seperti plastik transparan Seperti yang ditampilkan pada Gambar 3. Penghalang diberikan cahaya sehingga objek dibelakang penghalang tidak terlihat dengan sempurna.

Pada pengujian ini akan diberikan tiga skenario yaitu objek ditutupi penghalang penuh, sebagian dan tanpa penghalang.



Gambar 3. Pengujian sistem saat diberikan penghalang

3. HASIL DAN PEMBAHASAN

3.1 Detail Iterasi Pengambilan Data

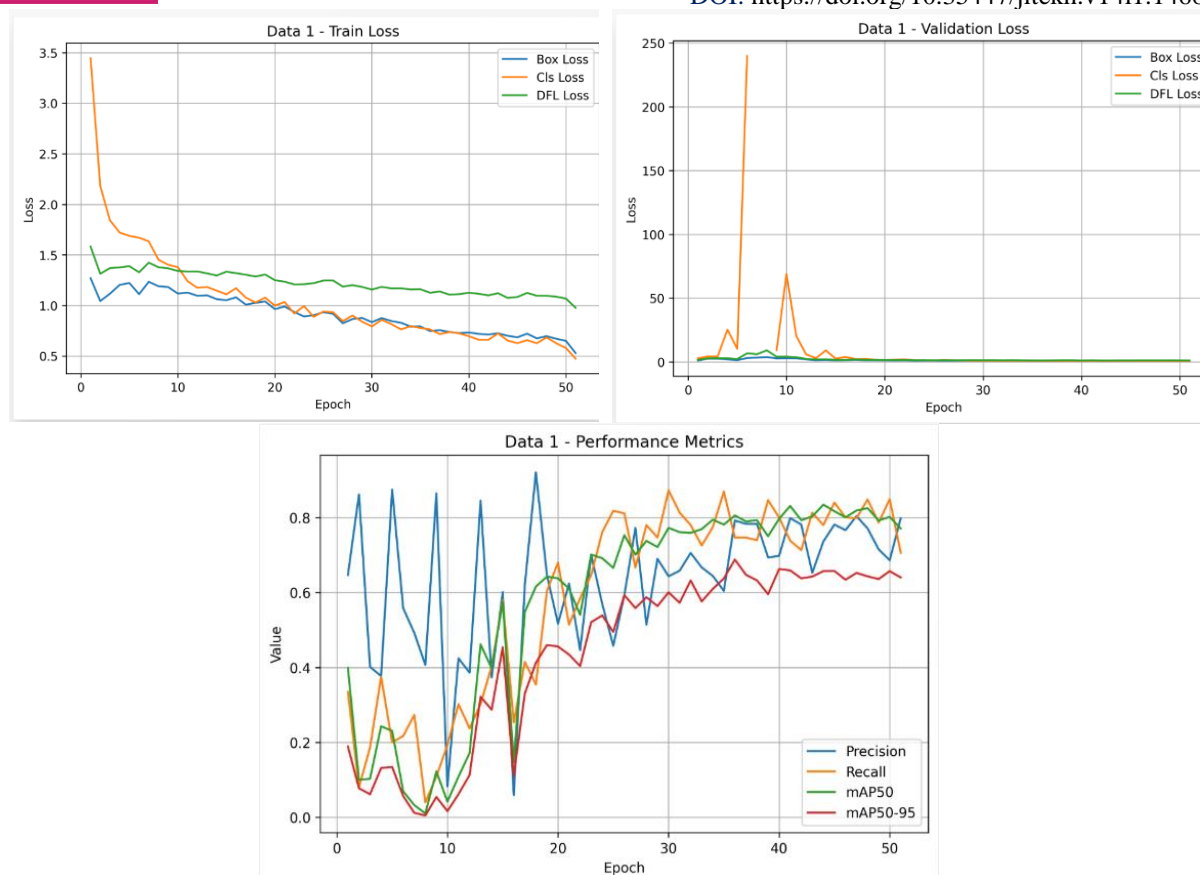
Pengambilan data foto dan pelatihan data dengan proses augmentasi dilakukan dalam tiga sesi (iterasi) yang didorong oleh kebutuhan untuk mencapai kriteria keberhasilan akurasi minimal 85% dengan menggunakan parameter $epochs=300$, $imgsz=640$, dan $patience=15$. Setiap iterasi data bertujuan untuk memperbaiki kelemahan akurasi yang terlihat pada model sebelumnya. Tabel 1 menampilkan tingkat akurasi setelah dilakukan pelatihan data untuk setiap iterasi. Pada penelitian ini, data hanya dibagi menjadi train dan valid tanpa memasukkan test.

Tabel 1. Hasil Iterasi Training Berdasarkan Penambahan Data

| Iterasi | Tujuan Utama | Total gambar asli | Setelah Augmentasi | Pembagian Data | | mAP50-95 | Akurasi |
|-------------|---------------------|-------------------|--------------------|----------------|-------|----------|---------|
| | | | | Train | Valid | | |
| Ke-1 | Pengambilan 90 foto | 90 | 270 | 216 | 54 | 0,68 | 68% |
| Ke-2 | Penambahan 56 foto | 146 | 438 | 350 | 88 | 0,8 | 80% |
| Ke-3 | penambahan 144 foto | 290 | 870 | 696 | 174 | 0,85 | 85% |

3.2 Analisis Iterasi Pertama

Iterasi pertama merupakan data awal untuk pelatihan model Yolo11 dengan jumlah foto sebanyak 90 foto. Selanjutnya dilakukan augmentasi data dan melipat gandakan foto menjadi 270 foto. Pada tahap ini, model dilatih selama 51 epoch seperti yang ditampilkan Gambar 4. Meskipun parameter maksimum pelatihan ditetapkan sebesar 300 epoch, proses training dapat berhenti lebih awal (*early stopping*) ketika tidak terjadi peningkatan performa dalam sejumlah epoch tertentu sesuai parameter *patience*. Hasil pelatihan menunjukkan bahwa model sudah mulai mampu mempelajari pola visual objek, tetapi performanya belum stabil. Hal ini terlihat dari nilai metrik yang masih berfluktuasi cukup besar pada awal pelatihan, terutama pada komponen validasi.



Gambar 4. Hasil *training* pengambilan data pertama

Pada awal epoch, nilai *precision* dan *recall* hanya berada pada tingkat menengah, karena model masih beradaptasi dengan dataset awal yang terbatas. Hal ini sejalan dengan temuan Sapkota dkk. [18] yang melaporkan bahwa YOLO11 cenderung overfitting pada dataset kecil, sehingga performa awal terbatas. Penyertaan augmentasi data pada pengambilan citra bertujuan untuk meningkatkan volume, kualitas, dan keragaman data pelatihan [19]. Dengan penambahan data yang tepat, model dapat belajar fitur yang lebih representatif. Pada iterasi ini, loss menurun lambat karena kompleksitas awal jaringan. Dengan kata lain, iterasi pertama merupakan fondasi pembelajaran awal, namun memerlukan penambahan data dan pelatihan lanjutan agar performanya meningkat secara signifikan.

Perkembangan paling penting pada iterasi pertama terlihat ketika model mulai mendekati titik optimum pada pertengahan pelatihan. Nilai *precision* tertinggi mencapai 0,92089 pada epoch 18, sedangkan nilai *recall* tertinggi mencapai 0,87281 pada epoch 30. Nilai *mAP50* tertinggi tercatat sebesar 0,83465 pada epoch 44, dan *mAP50-95* tertinggi mencapai 0,68800 pada epoch 36. Hasil ini menunjukkan bahwa meskipun iterasi pertama belum mencapai performa final yang diharapkan, model sudah memiliki fondasi pembelajaran yang cukup baik.

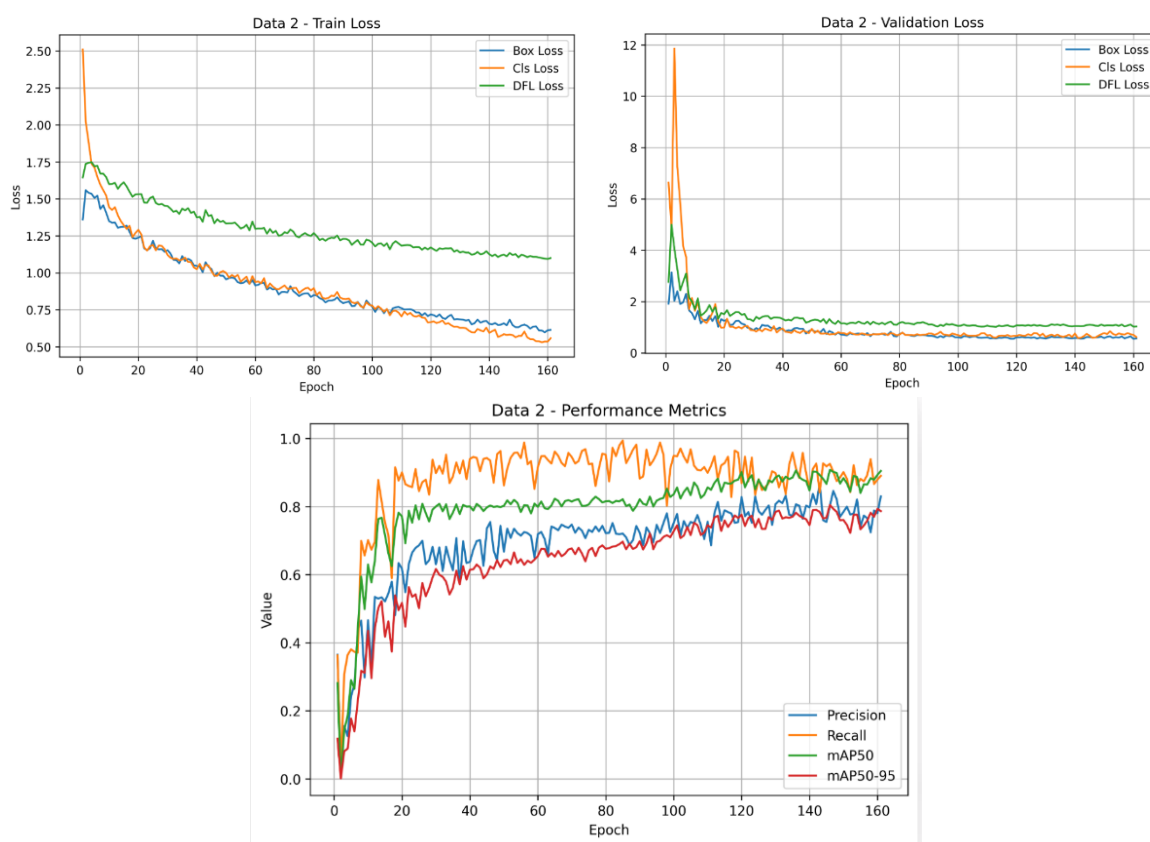
Dari sisi loss, penurunan terjadi secara konsisten hingga akhir pelatihan. *Train box loss* turun hingga 0,52910, *train cls loss* turun hingga 0,47450, dan *train dfl loss* menurun menjadi 0,97768 pada epoch terakhir. Penurunan loss ini menandakan bahwa model semakin memahami hubungan antara citra input dan label target. Namun demikian, pada sisi validasi masih terdapat fluktuasi yang cukup tajam, terutama pada awal epoch. Salah satu indikasi penting adalah lonjakan *validation cls loss* yang sangat tinggi pada beberapa epoch awal, yang menunjukkan bahwa model belum sepenuhnya stabil dalam mengenali kelas objek.

Secara keseluruhan, iterasi pertama dapat dipandang sebagai tahap eksploratif. Model sudah menunjukkan kemampuan mendasar untuk mendeteksi objek, namun belum cukup kuat untuk diaplikasikan sebagai model final. Meskipun demikian, hasil iterasi pertama sangat penting karena menjadi titik awal untuk menentukan strategi perbaikan pada iterasi berikutnya. Dari data ini diketahui bahwa model membutuhkan dataset yang lebih kaya, variasi visual yang lebih luas, dan pelatihan kembali agar performanya meningkat secara signifikan.

3.3 Analisis Iterasi Kedua

Iterasi kedua menunjukkan peningkatan performa yang jauh lebih baik dibandingkan iterasi pertama, karena dataset diperbesar menjadi 146 foto asli dan 438 setelah augmentasi. Pada tahap ini, model terlatih selama 161 epoch, sehingga proses pembelajaran berlangsung lebih panjang dan lebih matang. Dengan data latih yang lebih banyak, terjadi peningkatan akurasi dan kestabilan model. Sebagai contoh, Puspita [20] melaporkan bahwa penerapan teknik augmentasi canggih (seperti *mosaic*, *mixup*, *cutmix*) meningkatkan mAP model YOLOv8 dari 74,9% menjadi 81,4% (kenaikan ~6,5%).

Pada epoch awal, model masih mengalami adaptasi. Nilai *precision* dan *recall* pada beberapa epoch awal sempat sangat rendah, bahkan pada epoch 2 model hanya memperoleh *precision* sekitar 0,03171 dan *recall* 0,02127. Kondisi ini menunjukkan bahwa model masih membutuhkan waktu untuk menyesuaikan bobot terhadap data yang baru. Namun setelah melewati fase awal tersebut, performa model mulai meningkat secara signifikan hal ini dapat dilihat pada Gambar 5.



Gambar 5. Hasil *training* pengambilan data kedua

Salah satu pencapaian paling penting pada iterasi kedua adalah nilai *recall* tertinggi yang mencapai 0,99394 pada epoch 85. Nilai ini menunjukkan bahwa model hampir sempurna dalam menemukan objek yang ada pada data validasi. Pada saat yang sama, *precision* tertinggi tercatat sebesar 0,86699 pada epoch 143, sedangkan *mAP50* tertinggi mencapai 0,90784 dan *mAP50-95* tertinggi mencapai 0,80480, keduanya pada epoch 146. Ini merupakan peningkatan besar dibanding iterasi pertama, terutama pada metrik *mAP50-95* yang merupakan indikator penting untuk menilai kualitas deteksi pada berbagai ambang *Intersection over Union*. Hal ini menunjukkan bahwa penambahan data pelatihan dan epoch memperbaiki kualitas deteksi. Penelitian sebelumnya juga menunjukkan bahwa peningkatan epoch pelatihan umumnya meningkatkan performa model tersebut[21]. Optimasi YOLO11 dengan penyesuaian hiperparameter dan augmentasi dapat meningkatkan recall hingga 0,92, konsisten dengan kenaikan recall pada iterasi kedua[22].

Kinerja iterasi kedua menandakan bahwa model sudah mulai memasuki fase pembelajaran yang lebih stabil. Penurunan *train loss* dan *validation loss* berlangsung lebih konsisten daripada iterasi pertama. *Train box loss* terendah tercatat 0,59803, *train cls loss* terendah 0,53055, dan *train dfl loss* terendah 1,09399. Pada sisi validasi,

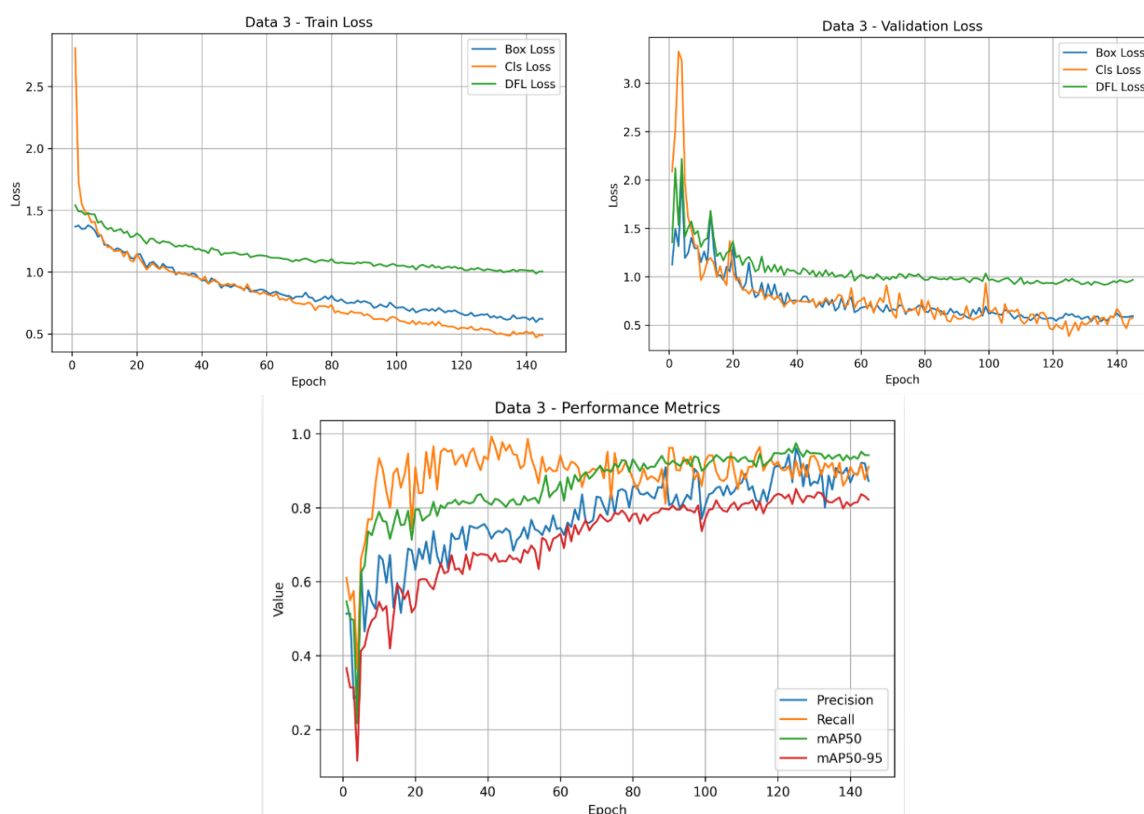
val box loss minimum mencapai 0,54778, *val cls loss* minimum 0,57540, dan *val dfl loss* minimum 1,01252. Angka-angka ini menunjukkan bahwa model tidak hanya semakin baik dalam menyesuaikan data latih, tetapi juga semakin mampu melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya.

Iterasi kedua juga memperlihatkan pola yang menarik, yaitu adanya perbedaan waktu optimum antara metrik-metrik evaluasi. *Recall* tertinggi dicapai lebih awal dibandingkan *precision*, sedangkan *mAP50* dan *mAP50-95* muncul pada epoch yang hampir sama di bagian akhir pelatihan. Hal ini menunjukkan bahwa model terlebih dahulu menjadi sangat sensitif dalam menemukan objek, kemudian semakin matang dalam menentukan batas prediksi dan kelas objek secara tepat. Dalam konteks deteksi objek, pola ini sangat positif karena menandakan proses pembelajaran berjalan bertahap dari deteksi kasar menuju deteksi yang lebih presisi.

Secara umum, iterasi kedua dapat dinilai sebagai tahap transisi menuju performa tinggi. Jika iterasi pertama berfungsi sebagai fondasi, maka iterasi kedua membuktikan bahwa penambahan data dan pelatihan lanjutan mampu menghasilkan model yang lebih kuat, lebih sensitif, dan lebih akurat. Namun, meskipun performanya jauh lebih baik, model masih belum mencapai titik final yang benar-benar optimal. Oleh karena itu, dilakukan iterasi ketiga sebagai upaya untuk memaksimalkan kualitas deteksi.

3.4 Analisis Iterasi Ketiga

Pada iterasi ketiga (290 foto asli, 870 setelah augmentasi), pelatihan dilakukan selama 145 epoch dan menunjukkan pola pembelajaran yang jauh lebih stabil dibandingkan dua iterasi sebelumnya seperti yang ditampilkan pada Gambar 6. Pada tahap ini, model tidak hanya mengalami peningkatan performa, tetapi juga menunjukkan konvergensi yang lebih konsisten.



Gambar 6. Hasil *training* pengambilan data ketiga

Pada awal pelatihan, model sudah memiliki kemampuan dasar yang cukup baik. Nilai *precision* pada epoch pertama mencapai 0,51340, sedangkan *recall* berada pada 0,61016. Angka ini lebih baik dibandingkan iterasi sebelumnya pada titik awal, yang menunjukkan bahwa model telah membawa pengetahuan awal dari pelatihan sebelumnya atau bahwa dataset tambahan pada iterasi ketiga lebih representatif. Meskipun masih terjadi fluktuasi pada beberapa epoch awal, model jauh lebih cepat pulih dan menunjukkan peningkatan performa yang konsisten.

Puncak performa pada iterasi ketiga dicapai pada epoch 125, ketika *precision* mencapai 0,96013, *mAP50* mencapai 0,97450, dan *mAP50-95* mencapai 0,85082. Ini adalah hasil terbaik sepanjang seluruh proses pelatihan.



Nilai *recall* tertinggi mencapai 0,99207 pada epoch 41, yang menunjukkan bahwa model hampir sempurna dalam mendeteksi seluruh objek target. Pada sisi loss, *train box loss* terendah tercatat 0,59554, *train cls loss* terendah 0,47099, dan *train dfl loss* terendah 0,98770, seluruhnya pada epoch 143. Sementara itu, *val box loss* terendah adalah 0,53778 pada epoch 132, *val cls loss* terendah 0,38490 pada epoch 125, dan *val dfl loss* terendah 0,91375 pada epoch 132.

Jika dibandingkan dengan dua iterasi sebelumnya, iterasi ketiga memperlihatkan kestabilan yang lebih baik pada hampir semua metrik. Model tidak hanya mampu mendeteksi objek dengan tingkat akurasi yang sangat tinggi, tetapi juga memiliki kemampuan lokalisasi yang baik. Pencapaian *mAP50-95* sebesar 0,85082 sangat penting karena metrik ini mengukur kualitas deteksi pada berbagai tingkat ambang IoU, sehingga lebih ketat dan lebih representatif terhadap performa model secara keseluruhan. Dengan kata lain, nilai ini menunjukkan bahwa model benar-benar telah belajar mengenali objek secara akurat dan konsisten.

Selain itu, iterasi ketiga memperlihatkan bahwa model mampu mempertahankan performa tinggi hingga akhir pelatihan. Nilai akhir pada epoch 145 tetap tinggi, dengan *precision* 0,87231, *recall* 0,91080, *mAP50* 0,94217, dan *mAP50-95* 0,82198. Walaupun sedikit menurun dari titik optimum, hasil akhir ini tetap sangat baik dan menunjukkan bahwa model memiliki kestabilan yang tinggi. Penurunan kecil pada akhir pelatihan dapat diinterpretasikan sebagai awal saturasi pembelajaran atau indikasi *overfitting* ringan, tetapi belum pada tingkat yang merusak performa model secara keseluruhan.

3.5 Perbandingan Ketiga Iterasi

Jika ketiga iterasi dibandingkan secara langsung, terlihat adanya peningkatan kualitas model yang sangat jelas. Iterasi pertama memberikan hasil dasar dengan *mAP50-95* tertinggi 0,68800. Iterasi kedua meningkatkan capaian tersebut menjadi 0,80480, dan iterasi ketiga berhasil mencapai 0,85082. Tren yang sama juga terlihat pada *mAP50*, yang meningkat dari 0,83465 pada iterasi pertama menjadi 0,90784 pada iterasi kedua, dan akhirnya mencapai 0,97450 pada iterasi ketiga. Tren peningkatan ini sesuai dengan hasil Abdulghani dkk [23] yang menunjukkan bahwa penambahan data augmentasi dapat menaikkan *mAP@0.5* hingga +13%. Hasil ini menegaskan bahwa pengayaan dataset secara signifikan menguatkan kemampuan deteksi model.

Tabel 2. Perbandingan Kinerja Terbaik antar Iterasi

| Parameter | Iterasi 1 | Iterasi 2 | Iterasi 3 |
|------------------------|-----------|-----------|-----------|
| Precision tertinggi | 0,92089 | 0,86699 | 0,96013 |
| Recall tertinggi | 0,87281 | 0,99394 | 0,99207 |
| mAP50 tertinggi | 0,83465 | 0,90784 | 0,97450 |
| mAP50-95 tertinggi | 0,68800 | 0,80480 | 0,85082 |
| Train box loss minimum | 0,52910 | 0,59803 | 0,59554 |
| Val box loss minimum | 0,74897 | 0,54778 | 0,53778 |

Dari Tabel 2 tampak bahwa iterasi ketiga menjadi yang terbaik secara keseluruhan. Iterasi kedua unggul pada *recall* tertinggi, tetapi iterasi ketiga unggul pada *precision*, *mAP50*, dan *mAP50-95*. Ini menunjukkan bahwa iterasi ketiga bukan hanya mampu mendeteksi hampir semua objek, tetapi juga mampu melakukannya dengan ketepatan yang sangat tinggi. Perpaduan antara *precision* yang tinggi dan *recall* yang sangat tinggi merupakan ciri model yang matang dan seimbang.

Perbandingan ketiga iterasi juga menunjukkan bahwa penambahan data pada tiap tahap memberikan dampak positif terhadap performa model. Iterasi pertama masih didominasi oleh pembelajaran dasar, iterasi kedua memperlihatkan peningkatan signifikan setelah data ditambah, dan iterasi ketiga membuktikan bahwa model dapat mencapai tingkat akurasi optimal setelah dataset semakin diperluas dan pelatihan disempurnakan. Dengan demikian, pendekatan iteratif terbukti efektif untuk meningkatkan kualitas deteksi Yolo11 dalam konteks pengenalan peralatan perawatan dan instrumen pesawat udara.

3.6 Pembahasan Umum ketiga Iterasi

Secara keseluruhan, hasil tiga iterasi menunjukkan bahwa model Yolo11 sangat cocok digunakan untuk tugas pengenalan otomatis objek dalam lingkungan pendidikan penerbangan. Studi Olson & Munson [25] juga menemukan bahwa model CNN dapat membaca instrumen analog pesawat (seperti indikator kecepatan udara dan sikap) dengan akurasi tinggi, yang mendukung potensi aplikasi model ini. Evaluasi menggunakan *confusion matrix* juga dilakukan untuk menghitung metrik *Precision*, *Recall*, dan *mAP* tiap kelas, serta memberikan gambaran detail mengenai kesalahan deteksi. Penggunaan metrik ini umum dalam studi deteksi objek, sebagaimana ditegaskan Hendriko & Hermanto [26] Model mampu belajar secara bertahap dari data yang terbatas menuju performa yang



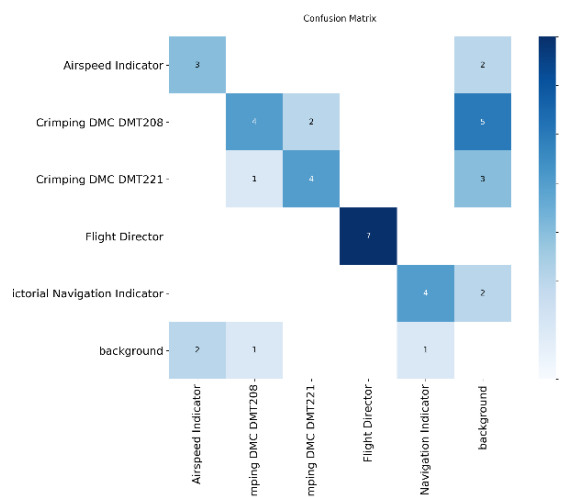
sangat baik setelah dilakukan penambahan data dan pelatihan berulang. Hal ini penting karena objek yang diteliti, yaitu peralatan perawatan dan instrumen pesawat udara, memiliki karakteristik visual yang spesifik, kadang serupa satu sama lain, dan sangat dipengaruhi oleh sudut pengambilan gambar serta pencahayaan.

Kenaikan performa dari iterasi pertama ke ketiga juga menunjukkan bahwa kualitas dataset memegang peranan penting dalam keberhasilan model. Dataset yang lebih beragam, seimbang, dan mencakup berbagai kondisi visual akan membantu model membangun representasi fitur yang lebih kuat. Selain itu, nilai *validation loss* yang semakin rendah di iterasi ketiga membuktikan bahwa model tidak hanya menghafal data latih, tetapi benar-benar mampu melakukan generalisasi terhadap data baru.

Dari sudut pandang penerapan praktis, hasil ini sangat relevan untuk pendidikan vokasi penerbangan. Sistem pengenalan otomatis berbasis Yolo11 dapat digunakan sebagai alat bantu pembelajaran agar taruna lebih cepat mengenali alat dan instrumen pesawat. Dengan adanya sistem ini, proses belajar menjadi lebih interaktif, efisien, dan sesuai dengan tuntutan era digital. Selain itu, model yang telah mencapai performa optimal pada iterasi ketiga dapat dijadikan dasar untuk pengembangan aplikasi pembelajaran yang lebih lanjut, misalnya dengan integrasi kamera *real-time* atau antarmuka berbasis web.

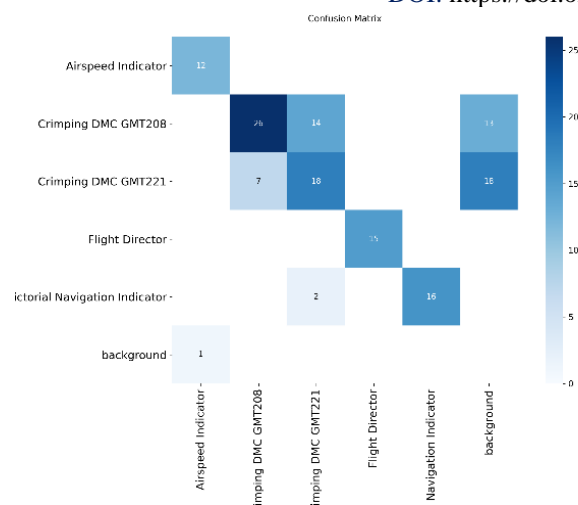
3.7 Evaluasi Kinerja Model Melalui Confusion Matrix

Selain menggunakan metrik precision, recall, mAP50, dan mAP50-95, evaluasi performa model juga dilakukan dengan confusion matrix untuk melihat distribusi hasil prediksi pada setiap kelas objek. Confusion matrix digunakan untuk mengetahui sejauh mana model mampu mengenali objek secara tepat, sekaligus mengidentifikasi kelas yang masih sering tertukar. Pada penelitian ini, confusion matrix ditampilkan untuk tiga iterasi pelatihan sehingga perbedaan kemampuan klasifikasi model dapat dianalisis secara lebih rinci.




Gambar 7. Confusion matrix iterasi pertama

Berdasarkan Gambar 7 mengenai confusion matrix iterasi pertama, model sudah mampu mengenali kelas-kelas utama seperti Airspeed Indicator, Flight Director, dan Pictorial Navigation Indicator dengan cukup baik. Namun, masih terlihat kesalahan klasifikasi yang cukup dominan pada dua kelas alat *crimping*, yaitu *Crimping DMC GMT208* dan *Crimping DMC GMT221*. Kedua objek tersebut memiliki kemiripan bentuk yang tinggi sehingga model masih sering tertukar dalam proses prediksi. Selain itu, masih terdapat prediksi terhadap background yang menunjukkan bahwa model belum sepenuhnya stabil dalam membedakan objek dengan area non-objek.



Gambar 8. Confusion matrix iterasi kedua

Pada confusion matrix iterasi kedua seperti yang terlihat pada Gambar 8, performa model menunjukkan peningkatan yang lebih baik dibandingkan iterasi pertama. Sebaran prediksi benar pada diagonal utama menjadi lebih jelas, khususnya pada kelas Flight Director dan Pictorial Navigation Indicator. Meskipun demikian, kesalahan antara *Crimping* DMC GMT208 dan *Crimping* DMC GMT221 masih tetap muncul, walaupun frekuensinya cenderung lebih kecil. Hal ini menunjukkan bahwa penambahan data dan proses pelatihan ulang membantu model dalam mempelajari ciri visual objek secara lebih baik, tetapi masih diperlukan variasi data tambahan agar perbedaan antar dua alat *crimping* yang mirip dapat dikenali dengan lebih akurat.



Gambar 9. Confusion matrix iterasi ketiga

Pada iterasi ketiga sesuai Gambar 9, confusion matrix memperlihatkan hasil yang paling stabil dibandingkan dua iterasi sebelumnya. Prediksi benar masih dominan pada masing-masing kelas objek, terutama pada Flight Director yang terdeteksi konsisten sebagai kelas yang paling mudah dikenali. Namun demikian, kesalahan klasifikasi antara *Crimping* DMC GMT208 dan *Crimping* DMC GMT221 masih tetap menjadi tantangan utama. Selain itu, beberapa prediksi terhadap background dan kesalahan kecil pada kelas Airspeed Indicator serta Pictorial Navigation



Indicator menunjukkan bahwa model masih sensitif terhadap perbedaan sudut pandang, pencahayaan, dan keberadaan gangguan visual.

Secara keseluruhan, hasil confusion matrix menunjukkan bahwa model Yolo11 memiliki kemampuan klasifikasi yang baik pada objek-objek penelitian, tetapi masih mengalami kesulitan pada dua kelas alat yang memiliki bentuk serupa. Temuan ini memperkuat hasil evaluasi sebelumnya bahwa penambahan data latih dan variasi kondisi citra sangat berpengaruh terhadap peningkatan performa model. Dengan demikian, confusion matrix tidak hanya berfungsi sebagai pelengkap evaluasi, tetapi juga memberikan gambaran yang lebih jelas mengenai kelas-kelas yang masih perlu diperbaiki pada pengembangan sistem berikutnya.

3.8 Evaluasi Kinerja Model Terbaik dan Pembahasan

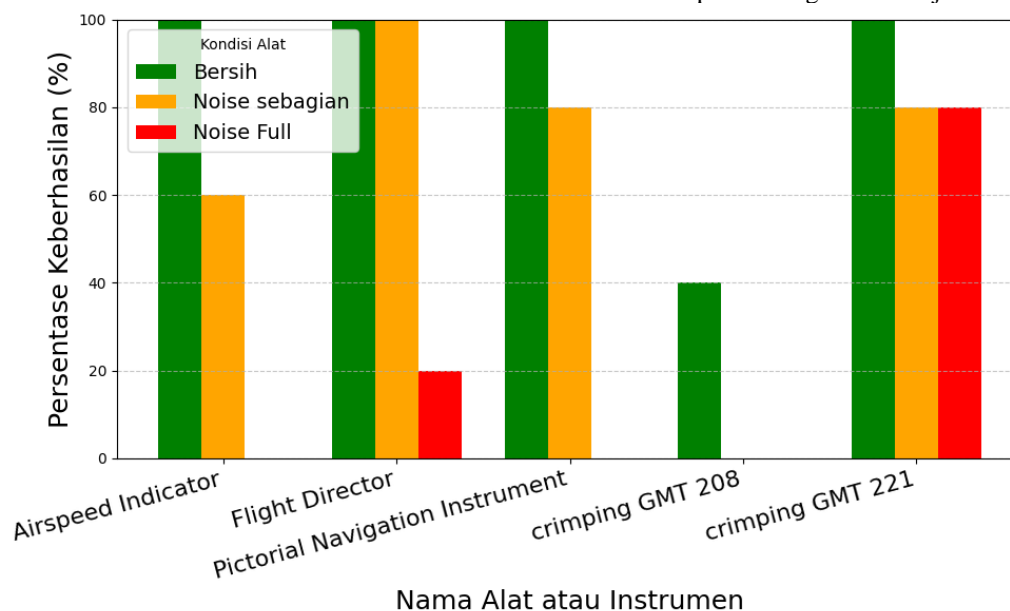
Model terbaik (Iterasi 3) diuji secara langsung pada *live video* menggunakan webcam 1080p dengan tiga skenario pengujian utama: kondisi normal (tanpa gangguan), gangguan sebagian, dan gangguan penuh. Data menunjukkan variasi signifikan dalam *robustness* (ketahanan) operasional antar instrumen.

Tabel 3 menyajikan persentase keberhasilan setiap instrumen dari total lima kali pengujian per kondisi. Mayoritas instrumen menunjukkan kinerja optimal (100% Keberhasilan) dalam kondisi ideal (kondisi normal), yang mencakup Airspeed Indicator, Flight Director, Pictorial Navigation Instrument, dan *Crimping* GMT 221. Hasil ini menegaskan validitas fungsionalitas dasar alat dalam ketiadaan *gangguan*. Pengecualian fundamental adalah *Crimping* GMT 208, yang hanya mencapai 40% keberhasilan bahkan dalam kondisi normal, mengindikasikan adanya defisiensi inheren dalam desain yang menyebabkan sistem sulit membedakan antara *Crimping* GMT 208 dengan *Crimping* GMT 221.

Tabel 3. Tabel ringkasan hasil pengujian sistem saat diberikan *gangguan*

| Alat | Kondisi | Total Uji | Total Keberhasilan | Keberhasilan (%) |
|--|-------------------|-----------|--------------------|------------------|
| Airspeed Indicator | Kondisi normal | 5 | 5 | 100% |
| | Gangguan penuh | 5 | 0 | 0% |
| | Gangguan sebagian | 5 | 3 | 60% |
| Flight Director | Kondisi normal | 5 | 5 | 100% |
| | Gangguan penuh | 5 | 1 | 20% |
| | Gangguan sebagian | 5 | 5 | 100% |
| Pictorial Navigation Instrument | Kondisi normal | 5 | 5 | 100% |
| | Gangguan penuh | 5 | 0 | 0% |
| | Gangguan sebagian | 5 | 4 | 80% |
| crimping GMT 208 | Kondisi normal | 5 | 2 | 40% |
| | Gangguan penuh | 5 | 0 | 0% |
| | Gangguan sebagian | 5 | 0 | 0% |
| crimping GMT 221 | Kondisi normal | 5 | 5 | 100% |
| | Gangguan penuh | 5 | 4 | 80% |
| | Gangguan sebagian | 5 | 4 | 80% |

Grafik pada Gambar 10 secara visual memperkuat temuan penurunan kinerja setiap instrumen seiring meningkatnya *gangguan*. Ketahanan instrumen diuji secara progresif seiring peningkatan tingkat *gangguan*. Dalam kondisi gangguan sebagian, Flight Director menunjukkan *robustness* sempurna dengan 100% keberhasilan, sejajar dengan kinerja kondisi normal. *Crimping* GMT 221 dan Pictorial Navigation Instrument mempertahankan efektivitas tinggi (80%), menunjukkan toleransi *gangguan* yang baik. Namun, kinerja Airspeed Indicator menurun signifikan menjadi 60%, menunjukkan sensitivitas yang lebih tinggi. Poin kritisnya, *Crimping* GMT 208 mengalami kegagalan total (0%), menegaskan ketidakmampuan beroperasi dibawah *gangguan* sekecil apa pun.



Gambar 10. Persentase Keberhasilan Uji Alat berdasarkan Kondisi

Kondisi Gangguan penuh berfungsi sebagai ambang batas kegagalan bagi sebagian besar instrumen. Instrumen navigasi presisi seperti *Airspeed Indicator* dan *Pictorial Navigation Instrument* mencapai titik kegagalan total (0%), mengonfirmasi sensitivitas tinggi mereka terhadap *gangguan* spektral luas. Kontras yang tajam terjadi pada *Crimping GMT 221*, yang berhasil mempertahankan tingkat keberhasilan 80%; hasil ini menempatkannya sebagai instrumen paling *robust* dalam keseluruhan studi. Sementara itu, *Flight Director* menunjukkan ketahanan minimal dengan 20% keberhasilan, sebuah penurunan drastis namun tetap lebih unggul dibandingkan kegagalan total instrumen navigasi lainnya. Berdasarkan temuan ini, dapat disimpulkan bahwa *Crimping GMT 221* memiliki toleransi *gangguan* tertinggi, menjadikannya pilihan operasional yang paling andal dalam lingkungan yang dinamis atau terganggu. Sebaliknya, *Crimping GMT 208* terbukti tidak *reliable* pada semua kondisi, sementara *Airspeed Indicator* dan *Pictorial Navigation Instrument* sangat rentan terhadap *gangguan* berintensitas tinggi.

4. KESIMPULAN

Berdasarkan hasil penelitian dan pengujian terhadap sistem pengenalan otomatis peralatan perawatan dan instrumen pesawat udara berbasis Yolo11, dapat disimpulkan bahwa model berhasil diimplementasikan secara efektif untuk mendeteksi dan mengenali objek-objek penelitian di lingkungan Laboratorium Avionic Politeknik Penerbangan Medan. Proses pelatihan yang dilakukan melalui tiga kali iterasi menunjukkan bahwa performa model meningkat secara bertahap seiring dengan penambahan data pelatihan. Iterasi pertama dan kedua belum mampu mencapai target akurasi 85%, sehingga dilakukan penambahan data kembali hingga pada iterasi ketiga model berhasil mencapai nilai mAP50-95 sebesar 0,85 sesuai dengan kriteria keberhasilan penelitian. Hasil pengujian real-time menunjukkan bahwa sistem bekerja sangat baik pada kondisi pencahayaan normal tanpa *gangguan*, dengan tingkat keberhasilan deteksi mencapai 100% pada sebagian besar instrumen. Namun, performa model menurun ketika diberikan *gangguan* visual, terutama pada kondisi *gangguan* sebagian dan *gangguan* penuh. Hal ini menunjukkan bahwa ketahanan model terhadap *gangguan* optik masih perlu ditingkatkan agar dapat digunakan secara lebih stabil dalam berbagai kondisi pengamatan. Selain itu, hasil pengujian memperlihatkan bahwa *Crimping GMT 221* memiliki tingkat *robustness* tertinggi, sedangkan *Crimping GMT 208* menunjukkan performa terendah. Secara keseluruhan, penelitian ini membuktikan bahwa Yolo11 memiliki potensi yang baik untuk diterapkan sebagai alat bantu pembelajaran yang efektif dan berpotensi besar diterapkan dalam pembelajaran berbasis kecerdasan buatan di bidang vokasi penerbangan.

**REFERENSI**

- [1] Australian Transport Safety Bureau, “Screwdriver tip left in engine during maintenance results in blade failure on take-off,” ATSB. [Online]. Available: <https://www.atsb.gov.au/media/news-items/2021/tool-control>
- [2] N. Zendejdel, H. Chen, and M. C. Leu, “Real-time tool detection in smart manufacturing using You-Only-Look-Once (YOLO) v5,” *Manuf. Lett.*, vol. 35, pp. 1052–1059, 2023.
- [3] Y. Zhang, “AI-Driven Transformation of Vocational Education,” *Int. J. Knowl. Manag.*, vol. 21, no. 1, 2024.
- [4] L. T. Ramos and A. D. Sappa, “A decade of you only look once (yolo) for object detection: A review,” *IEEE Access*, vol. 13, pp. 192747–192794, 2025.
- [5] N. Pati *et al.*, “A real-time industrial safety automation using YOLO architectures leveraging diverse chromatic domains,” *Sci. Rep.*, 2026.
- [6] M. Yaseen, “What is YOLOv9: An in-depth exploration of the internal features of the next-generation object detector,” *arXiv Prepr. arXiv2409.07813*, 2024.
- [7] L. Ali, F. Alnajjar, M. M. A. Parambil, M. I. Younes, Z. I. Abdelhalim, and H. Aljassmi, “Development of YOLOv5-based real-time smart monitoring system for increasing lab safety awareness in educational institutions,” *Sensors*, vol. 22, no. 22, p. 8820, 2022.
- [8] B.-H. Lin, J.-C. Chen, and J.-J. J. Lien, “Defect inspection using modified YoloV4 on a stitched image of a spinning tool,” *Sensors*, vol. 23, no. 9, p. 4476, 2023.
- [9] A. Lu, P. Liu, J. Yang, Z. Li, and K. Wang, “Tailhook Recognition for Carrier-Based Aircraft Based on YOLO with Bi-Level Routing Attention,” *Algorithms*, vol. 17, no. 11, p. 488, 2024.
- [10] Z. He, Y. He, and Y. Lv, “DT-YOLO: An improved object detection algorithm for key components of aircraft and staff in airport scenes based on YOLOv5,” *Sensors*, vol. 25, no. 6, p. 1705, 2025.
- [11] R. Wen, Y. Yao, Z. Li, Q. Liu, Y. Wang, and Y. Chen, “LESM-YOLO: An improved aircraft ducts defect detection model,” *Sensors*, vol. 24, no. 13, p. 4331, 2024.
- [12] G. Morales Méndez and F. del Cerro Velázquez, “Augmented reality in Industry 4.0 assistance and training areas: a systematic literature review and bibliometric analysis,” *Electronics*, vol. 13, no. 6, p. 1147, 2024.
- [13] H.-J. Kwon, S.-I. Lee, J.-H. Park, and C.-S. Kim, “Design of augmented reality training content for railway vehicle maintenance focusing on the axle-mounted disc brake system,” *Appl. Sci.*, vol. 11, no. 19, p. 9090, 2021.
- [14] Y. Zhou and B. Zhao, “You Only Look Once 11 (YOLOv11) optimization for lightweight and accurate plant detection in uncrewed aerial vehicle imagery,” *PeerJ Comput. Sci.*, vol. 11, p. e3322, 2025.
- [15] A. A. Murat and M. S. Kiran, “A comprehensive review on YOLO versions for object detection,” *Eng. Sci. Technol. an Int. J.*, vol. 70, p. 102161, 2025, doi: <https://doi.org/10.1016/j.jestch.2025.102161>.
- [16] L. He, Y. Zhou, L. Liu, W. Cao, and J. Ma, “Research on object detection and recognition in remote sensing images based on YOLOv11,” *Sci. Rep.*, vol. 15, no. 1, p. 14032, 2025.
- [17] J. Chen, S. Pan, Y. Chan, Y. Ni, and D. Ye, “A new method based on YOLOv5 and multiscale data augmentation for visual inspection in substation,” *Sci. Rep.*, vol. 14, no. 1, p. 9362, 2024, doi: [10.1038/s41598-024-60126-2](https://doi.org/10.1038/s41598-024-60126-2).
- [18] R. Sapkota *et al.*, “YOLO advances to its genesis: A decadal and comprehensive review of the You Only Look Once (YOLO) series,” *Artif. Intell. Rev.*, vol. 58, no. 9, p. 274, 2025.
- [19] A. Mumuni and F. Mumuni, “Data augmentation: A comprehensive survey of modern approaches,” *Array*, vol. 16, p. 100258, 2022.
- [20] R. F. Puspita, M. Naufal, and F. Al Zami, “Improving YOLO Performance with Advanced Data Augmentation for Soccer Object Detection,” *J. Appl. Informatics Comput.*, vol. 9, no. 6, pp. 3601–3611, 2025.
- [21] J. Jonathan and D. Hermanto, “Penentuan Epochs Hasil Model Terbaik: Studi Kasus Algoritma YOLOv8,” *Digit. Transform. Technol.*, vol. 4, no. 2, pp. 792–798, 2024.
- [22] I. A. Zulkarnain and K. Kusrini, “Optimasi YOLOv11 Melalui Hyperparameter Tuning dan Data Augmentasi untuk Meningkatkan Akurasi Deteksi Kendaraan pada Kondisi Malam Hari: YOLOv11 Optimization Through Hyperparameter Tuning and Data Augmentation to Improve Vehicle Detection Accuracy at Night,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 4, pp. 294–1303, 2025.
- [23] A. Abdulghani, M. Abdulghani, W. Walters, and K. Abed, “Multiple data augmentation strategy for enhancing the performance of yolov7 object detection algorithm,” *J. Artif. Intell.*, vol. 5, p. 15, 2023.
- [24] Z. Xu, H. Zhao, P. Liu, L. Wang, G. Zhang, and Y. Chai, “SRTSOD-YOLO: stronger real-time small





- object detection algorithm based on improved YOLOv11 for UAV imageries,” *Remote Sens.*, vol. 17, no. 20, p. 3414, 2025.
- [25] M. Munson and C. F. Olson, “Real-Time Evaluation of Aircraft Instruments,” in *International Symposium on Visual Computing*, 2024, pp. 396–409.
- [26] V. Hendriko and D. Hermanto, “Performance comparison of YOLOv10, YOLOv11, and YOLOv12 models on human detection datasets,” *Brill. Res. Artif. Intell.*, vol. 5, no. 1, pp. 440–450, 2025.