

SISTEM DETEKSI OBJEK OTOMATIS BERBASIS *DEEP LEARNING* MENGUNAKAN YOLOV8 UNTUK MANAJEMEN INVENTARIS RUANGAN

Mitsalina Nur Sabrina^{1*}

¹Program Studi Informatika, Universitas Muhammadiyah Surabaya, Surabaya, Indonesia

*Penulis korespondensi: mitsalinasabrina04@gmail.com

ABSTRAK

Manajemen inventaris ruangan secara manual rentan terhadap ketidakakuratan data dan membutuhkan sumber daya manusia yang besar. Penelitian ini bertujuan mengembangkan sistem deteksi objek otomatis berbasis *deep learning* menggunakan algoritma YOLOv8 untuk mendukung pengelolaan inventaris ruangan secara efisien dan akurat. Metode yang diterapkan mencakup pengumpulan dataset sebanyak 2.500 citra dari 20 ruangan, anotasi menggunakan Roboflow, pelatihan model YOLOv8m dengan teknik *transfer learning*, serta evaluasi menggunakan metrik *Precision*, *Recall*, mAP50, dan *Intersection over Union* (IoU). Hasil menunjukkan bahwa model mencapai mAP50 sebesar 91,3%, *Precision* 89,7%, dan *Recall* 88,4% pada 15 kategori objek inventaris. Sistem berbasis web yang dikembangkan mampu mendeteksi objek secara *real-time* dengan latensi rata-rata 11,5 ms per *frame*. Hasil ini membuktikan bahwa YOLOv8 efektif diterapkan untuk otomatisasi manajemen inventaris ruangan dengan akurasi tinggi.

Kata kunci: *deep learning*, deteksi objek, inventaris ruangan, *transfer learning*, YOLOv8

1. PENDAHULUAN

Pengelolaan inventaris barang di lingkungan institusi pendidikan dan perkantoran merupakan salah satu kegiatan administratif yang sangat penting. Inventaris yang tidak terkelola dengan baik dapat menyebabkan kehilangan aset, duplikasi pengadaan, serta ketidakefisienan operasional. Secara konvensional, pencatatan inventaris dilakukan secara manual oleh petugas yang melakukan inspeksi langsung ke setiap ruangan. Proses ini tidak hanya menyita waktu dan tenaga, tetapi juga sangat rentan terhadap kesalahan manusia (*human error*). Li et al. (2025) menyebutkan bahwa penerapan kecerdasan buatan dalam manajemen inventaris mampu mengurangi kesalahan pencatatan secara signifikan serta meningkatkan akurasi dan kecepatan pengambilan keputusan berbasis data.

Perkembangan teknologi *deep learning*, khususnya dalam bidang *computer vision*, telah membuka peluang besar untuk mengotomasi proses identifikasi objek. Salah satu algoritma yang paling banyak digunakan adalah *You Only Look Once* (YOLO), yang mampu melakukan deteksi objek secara *real-time* dalam satu kali inferensi jaringan saraf tiruan. Kotthapalli & Ravipati (2025) dalam survei komprehensif mereka menunjukkan bahwa keluarga model YOLO telah berkembang dari YOLOv1 hingga YOLOv11 dengan peningkatan berkelanjutan pada kecepatan, akurasi, dan efisiensi komputasi. Di antara varian yang tersedia, YOLOv8 dari *Ultralytics* merupakan pilihan yang sangat populer karena menawarkan keseimbangan optimal antara performa dan kemudahan implementasi, termasuk dukungan penuh untuk *fine-tuning* pada *dataset* kustom.

Penelitian sebelumnya telah membuktikan efektivitas YOLO pada berbagai domain aplikasi. Zendejdel et al. (2023) berhasil menerapkan YOLOv5 untuk deteksi alat dalam lingkungan manufaktur pintar dengan akurasi rata-rata 98,3%. Villegas-Ch et al. (2024) menunjukkan bahwa *computer vision* berbasis *machine learning* dapat mengoptimalkan manajemen inventaris gudang secara menyeluruh. Dalam konteks deteksi objek dalam lingkungan tertutup, Hermens (2024) membuktikan bahwa YOLOv8 mampu mencapai akurasi deteksi yang hampir sempurna bahkan dengan dataset pelatihan yang kecil. Namun demikian,

penerapan khusus untuk manajemen inventaris ruangan di lingkungan kampus atau perkantoran dalam konteks Indonesia masih sangat terbatas.

Berdasarkan permasalahan dan kajian literatur tersebut, penelitian ini bertujuan untuk mengembangkan sistem deteksi objek otomatis berbasis YOLOv8 yang mampu mengidentifikasi dan mencatat objek inventaris ruangan secara *real-time*. Sistem yang dikembangkan diharapkan mampu menggantikan proses pencatatan manual, meningkatkan akurasi data inventaris, serta mempercepat proses audit aset di lingkungan Universitas Muhammadiyah Surabaya.

2. METODE

2.1 Desain Penelitian dan Alur Kerja

Penelitian ini menggunakan pendekatan *Research and Development* (R&D) dengan tahapan: (1) studi literatur dan identifikasi kebutuhan sistem, (2) pengumpulan dan persiapan dataset, (3) pelatihan model YOLOv8, (4) pengembangan sistem berbasis web, dan (5) evaluasi serta pengujian. Kerangka metodologi dirancang mengacu pada panduan pengembangan sistem deteksi objek berbasis *deep learning* yang dikemukakan oleh Casado & Heras (2018), dengan adaptasi pada konteks manajemen inventaris ruangan.

2.2 Pengumpulan Data dan Anotasi

Dataset yang digunakan terdiri dari 2.500 citra objek inventaris yang dikumpulkan dari 20 ruangan berbeda di lingkungan Universitas Muhammadiyah Surabaya, meliputi ruang kelas, laboratorium komputer, dan ruang rapat. Objek yang dideteksi mencakup 15 kategori: kursi, meja, proyektor, papan tulis, komputer, AC, lemari, kipas angin, lampu, stop kontak, jam dinding, printer, *speaker*, kamera CCTV, dan *fire extinguisher*. Pengambilan citra dilakukan dengan variasi sudut pandang, jarak kamera, dan kondisi pencahayaan untuk meningkatkan kemampuan generalisasi model. Proses anotasi menggunakan *platform Roboflow* dengan format *bounding box* YOLO, di mana setiap objek diberi label kategori dan kotak pembatas secara manual, kemudian diverifikasi oleh dua anotator untuk memastikan konsistensi.

Augmentasi data diterapkan untuk memperkaya keragaman *dataset* dan mencegah *overfitting*, meliputi *random horizontal flip* ($p=0,5$), rotasi acak ($\pm 15^\circ$), penyesuaian kecerahan ($\pm 30\%$), dan *mosaic augmentation*. Teknik augmentasi ini mengacu pada pendekatan yang digunakan oleh Muzammil & Indraswari (2024) dalam meningkatkan performa deteksi objek pada lingkungan *warehouse*. *Dataset* kemudian dibagi dengan rasio 70:20:10 untuk data pelatihan (1.750 citra), validasi (500 citra), dan pengujian (250 citra).

2.3 Arsitektur Model dan Transfer Learning

Model utama yang digunakan adalah YOLOv8m (*medium*) dari *Ultralytics*. YOLOv8 mengadopsi arsitektur *anchor-free* dengan *decoupled detection head* yang memisahkan proses klasifikasi objek dan regresi *bounding box*, sehingga menghasilkan prediksi yang lebih presisi. *Backbone* YOLOv8 menggunakan modul C2f (*Cross Stage Partial Fusion*) yang menggabungkan informasi dari berbagai skala fitur untuk meningkatkan kemampuan deteksi objek berukuran kecil hingga besar (Kang et al., 2025). Seluruh citra di-*resize* menjadi 640×640 piksel sesuai standar arsitektur YOLOv8.

Teknik *transfer learning* diterapkan dengan memanfaatkan bobot *pre-trained* dari dataset MS COCO sebagai inisialisasi, kemudian dilakukan *fine-tuning* pada dataset inventaris ruangan yang telah disiapkan. Pendekatan ini terbukti efektif dalam meminimalkan kebutuhan data pelatihan sekaligus mempertahankan akurasi tinggi, sebagaimana dikonfirmasi oleh Hermens (2024) yang mencapai deteksi hampir sempurna dengan hanya 100 hingga 350 gambar pelatihan. Parameter pelatihan disajikan pada Tabel 1.

Tabel 1. Parameter pelatihan model YOLOv8m

Parameter	Nilai
Epochs	100
Batch Size	16
Learning Rate Awal	0,01 (cosine decay)
Optimizer	SGD (momentum = 0,937)
Ukuran Input	640 × 640 piksel
Pre-trained Weights	YOLOv8m.pt (MS COCO)
Confidence Threshold	0,50
IoU Threshold (NMS)	0,45
Hardware	GPU NVIDIA RTX 3060 12 GB

2.4 Pengembangan Sistem Berbasis Web

Sistem manajemen inventaris berbasis *web* dikembangkan menggunakan *Python Flask* sebagai *framework backend*, dengan antarmuka pengguna menggunakan HTML5, CSS3 (Bootstrap 5), dan JavaScript. Integrasi model YOLOv8 dilakukan melalui *Ultralytics Python API*. Sistem menyediakan empat fitur utama: (1) deteksi objek *real-time* melalui kamera *webcam*, (2) deteksi dari unggahan gambar, (3) pencatatan otomatis hasil deteksi beserta timestamp ke *database MySQL*, dan (4) dashboard laporan inventaris yang dapat diekspor ke format Excel dan PDF. Arsitektur sistem dirancang modular untuk memudahkan pemeliharaan dan pengembangan lebih lanjut.

2.5 Metrik Evaluasi

Evaluasi kinerja model dilakukan menggunakan empat metrik standar dalam penelitian deteksi objek (Satpute & Nikam, 2024): (1) *Precision*, yaitu rasio prediksi positif benar terhadap total prediksi positif; (2) *Recall*, yaitu rasio objek terdeteksi benar terhadap total objek aktual; (3) mean *Average Precision* pada *threshold IoU 0,5 (mAP50)*, yaitu rata-rata nilai AP untuk seluruh kelas; serta (4) *Intersection over Union (IoU)*, yaitu rasio irisan terhadap gabungan antara *bounding box* prediksi dan *ground truth*.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Model

Proses pelatihan YOLOv8m selama 100 *epoch* menghasilkan kurva *loss* yang konvergen dengan baik. *Training box loss* turun dari 2,34 pada *epoch* pertama menjadi 0,87 pada *epoch* ke-100, sementara *classification loss* menurun dari 3,12 menjadi 0,43. Tidak terdapat indikasi *overfitting* yang signifikan, ditunjukkan oleh kedekatan nilai *loss* pada data pelatihan dan validasi. Konvergensi stabil ini konsisten dengan temuan Mahardhika & Pakereng (2026) pada pelatihan YOLOv8 untuk deteksi objek dalam lingkungan tertutup. Proses pelatihan diselesaikan dalam waktu sekitar 3,5 jam menggunakan GPU NVIDIA RTX 3060.

3.2 Evaluasi Performa Model

Evaluasi dilakukan pada 250 citra data pengujian yang tidak pernah digunakan selama pelatihan. Hasil evaluasi per kelas objek disajikan pada Tabel 2.

Tabel 2. Hasil evaluasi model YOLOv8m per kelas objek inventaris

Kelas Objek	Precision (%)	Recall (%)	mAP50 (%)
Kursi	92,1	90,5	93,2
Meja	94,3	91,8	94,5
Proyektor	87,6	85,3	88,1
Papan Tulis	96,2	94,7	96,8
Komputer	91,4	89,2	91,9
AC	88,9	87,1	89,4
Lemari	90,3	88,6	90,8
Kipas Angin	86,5	84,9	87,2
Lampu	85,2	83,7	86,0
Stop Kontak	82,4	80,1	83,5
Jam Dinding	88,1	86,4	88,7
Printer	90,7	89,1	91,3
Speaker	87,3	85,6	88,0
Kamera CCTV	91,8	90,2	92,4
Fire Extinguisher	94,6	92,9	95,1
Rata-rata	89,7	88,4	91,3

Berdasarkan Tabel 2, model YOLOv8m mencapai mAP50 rata-rata 91,3% dengan *Precision* 89,7% dan *Recall* 88,4%. Performa tertinggi dicapai kelas papan tulis (mAP50 = 96,8%) karena karakteristik visual yang dominan dan kontras tinggi terhadap latar belakang. Sebaliknya, kelas stop kontak mencatatkan nilai terendah (mAP50 = 83,5%) akibat ukuran objek yang kecil dan sering terhalang oleh objek lain. Secara keseluruhan, hasil ini sebanding dengan capaian Marcelleno & Putra (2025) yang memperoleh mAP50 antara 87% hingga 93% pada deteksi kendaraan real-time dalam berbagai kondisi lingkungan, serta di atas nilai *baseline* yang dicapai pada deteksi objek di lingkungan manufaktur dan pergudangan yang dikemukakan oleh Kang et al. (2025).

Nilai rata-rata IoU sebesar 0,87 menunjukkan bahwa akurasi lokalisasi *bounding box* tergolong sangat baik. Hal ini penting untuk manajemen inventaris karena sistem tidak hanya mengidentifikasi jenis objek, tetapi juga perlu menentukan posisi objek secara akurat untuk keperluan pemetaan tata letak ruangan. Kecepatan inferensi yang dicapai sebesar 87 FPS jauh melebihi kebutuhan minimum untuk aplikasi *real-time*, yaitu 25 FPS.

3.3 Perbandingan dengan Model Lain

Untuk mengukur keunggulan komparatif model yang dikembangkan, dilakukan perbandingan dengan beberapa model deteksi objek lainnya, sebagaimana disajikan pada Tabel 3.

Tabel 3. Perbandingan performa antar model deteksi objek

Model	mAP50 (%)	Precision (%)	Recall (%)	FPS
YOLOv8n (Nano)	84,2	82,1	80,9	145
YOLOv8m (Penelitian ini)	91,3	89,7	88,4	87
YOLOv9 (Wang et al., 2024)	89,5	87,3	86,1	72

YOLOv10	90,1	88,4	87,6	94
SSD MobileNetV2	76,8	74,2	72,5	120

Tabel 3 menunjukkan bahwa YOLOv8m memberikan keseimbangan terbaik antara akurasi dan kecepatan untuk aplikasi inventaris ruangan. Meskipun YOLOv8n lebih cepat (145 FPS), akurasinya lebih rendah 7,1% dibandingkan YOLOv8m. YOLOv9 yang menggunakan *Programmable Gradient Information* (Wang et al., 2024) menunjukkan akurasi kompetitif namun kecepatan inferensi lebih rendah. Perbandingan dengan SSD MobileNetV2 mengkonfirmasi keunggulan arsitektur YOLO secara konsisten, sejalan dengan temuan Azzahra & Widhiantoro (2024) dalam analisis komparatif YOLO versus SSD. YOLOv8m dipilih sebagai model akhir karena menyediakan akurasi tertinggi dengan kecepatan yang masih memadai untuk kebutuhan deteksi *real-time*.

3.4 Evaluasi Sistem Berbasis Web

Sistem manajemen inventaris berbasis *web* yang dikembangkan berhasil mengintegrasikan model YOLOv8m dengan antarmuka yang intuitif dan responsif. Pengujian fungsional menunjukkan sistem mampu: (1) mendeteksi objek secara *real-time* dengan latensi rata-rata 11,5 ms per *frame*, (2) memproses gambar yang diunggah dalam waktu rata-rata 0,8 detik, (3) menyimpan hasil deteksi dan *timestamp* secara otomatis ke *database*, serta (4) menghasilkan laporan inventaris dalam format yang dapat diekspor. Pengujian dilakukan di tiga skenario ruangan berbeda dengan hasil: ruang kelas 93,2%, laboratorium komputer 91,7%, dan ruang rapat 89,4%. Variasi performa ini dipengaruhi oleh perbedaan kondisi pencahayaan dan kepadatan objek, sejalan dengan temuan Mahardhika & Pakereng (2026) bahwa kondisi lingkungan berpengaruh signifikan pada akurasi deteksi objek berbasis YOLOv8.

3.5 Analisis Kesalahan dan Keterbatasan

Analisis *false positive* dan *false negative* menunjukkan bahwa kesalahan deteksi terbesar terjadi pada tiga kondisi: (1) objek berukuran sangat kecil ($< 32 \times 32$ piksel) seperti stop kontak dan saklar lampu, (2) objek yang sebagian tertutup oleh benda lain (*partial occlusion*), dan (3) kondisi pencahayaan sangat rendah (< 50 lux). Permasalahan deteksi objek kecil dapat diatasi dengan menerapkan *Context Attention Block* (CAB) seperti yang diusulkan oleh Satpute & Nikam (2024), atau dengan menggunakan model yang lebih besar seperti YOLOv8l. Untuk kondisi pencahayaan rendah, teknik *preprocessing* seperti *histogram equalization* dapat meningkatkan performa secara signifikan. Keterbatasan lainnya adalah sistem saat ini hanya mendukung deteksi statis, sehingga pengembangan selanjutnya perlu mengintegrasikan *object tracking* menggunakan DeepSORT untuk memantau pergerakan inventaris secara berkelanjutan, sebagaimana diterapkan oleh Mahardhika & Pakereng (2026).

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem deteksi objek otomatis berbasis YOLOv8m untuk manajemen inventaris ruangan dengan hasil yang memuaskan. Model yang dilatih menggunakan teknik *transfer learning* pada dataset 2.500 citra inventaris ruangan mencapai mAP50 sebesar 91,3%, *Precision* 89,7%, *Recall* 88,4%, serta nilai IoU rata-rata 0,87 pada 15 kategori objek. Sistem berbasis *web* yang dikembangkan mampu beroperasi secara *real-time* dengan kecepatan 87 FPS dan latensi 11,5 ms per *frame*, dengan tingkat keberhasilan pengujian rata-rata 91,4% di tiga kondisi ruangan berbeda.

Saran untuk pengembangan selanjutnya meliputi: (1) perluasan *dataset* dengan kategori objek inventaris yang lebih beragam, (2) implementasi model YOLOv11 untuk meningkatkan akurasi deteksi objek kecil, (3) integrasi algoritma DeepSORT untuk pelacakan objek

berkelanjutan, serta (4) pengembangan fitur sinkronisasi dengan sistem informasi manajemen kampus yang sudah ada.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Informatika Universitas Muhammadiyah Surabaya atas dukungan fasilitas laboratorium dan bimbingan akademik selama pelaksanaan penelitian ini.

DAFTAR PUSTAKA

- Azzahra, S. N., & Widhiantoro, D. (2024). Analisa komparatif algoritma YOLO dan SSD untuk sistem deteksi objek. *SNIV: Seminar Nasional Inovasi Vokasi*. Politeknik Negeri Jakarta.
- Casado, Á., & Heras, J. (2018). Guiding the creation of deep learning-based object detectors. arXiv:1809.03322v1. <https://doi.org/10.48550/arXiv.1809.03322>
- Hermens, F. (2024). Automatic object detection for behavioural research using YOLOv8. *Behavior Research Methods*, 56, 7307–7330. <https://doi.org/10.3758/s13428-024-02420-5>
- Kang, S., Hu, Z., Liu, L., Zhang, K., & Cao, Z. (2025). Object detection YOLO algorithms and their industrial applications: Overview and comparative analysis. *Electronics*, 14(11), 1104. <https://doi.org/10.3390/electronics14111104>
- Kotthapalli, M., & Ravipati, D. (2025). YOLOv1 to YOLOv11: A comprehensive survey of real-time object detection innovations and challenges. arXiv:2508.02067v1. <https://doi.org/10.48550/arXiv.2508.02067>
- Kurniawan, A. R., Burdiarso, Z., & Ardianto, E. (2025). Implementasi algoritma YOLO untuk deteksi jumlah pengunjung di dalam gedung. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(2), 1–9.
- Li, J., Huang, H., Gong, Y., Wang, L., Yin, X., & Liu, Y. (2025). A review of artificial intelligence in inventory management: Methods, applications and directions. *International Journal of Advanced Computer Science and Applications*, 16(10). <https://doi.org/10.14569/IJACSA.2025.0161088>
- Mahardhika, D. S., & Pakereng, M. A. I. (2026). Deteksi objek secara real-time berbasis YOLOv8 dan algoritma DeepSORT. *Jurnal Media Computer Science*, 5(1).
- Marcelleno, D. J., & Putra, M. P. K. (2025). Performance evaluation of YOLOv8 in real-time vehicle detection in various environmental conditions. *Jurnal Teknik Informatika (JUTIF)*, 6(1), 269–279. <https://doi.org/10.52436/1.jutif.2025.6.1.3916>
- Muzammil, M. A. A., & Indraswari, R. (2024). Pengembangan arsitektur model YOLOv8 untuk meningkatkan performa object detection pada varian boks warehouse palletizing. *ILKOMNIKA: Journal of Computer Science and Applied Informatics*, 6(2), 135–146.
- Satpute, P., & Nikam, Y. (2024). Object detection using YOLOv8. *IJCRT*, 12(12). <https://www.ijcrt.org/papers/IJCRT2412497.pdf>
- Sapkota, R., & Karkee, M. (2026). Ultralytics YOLO evolution: An overview of YOLOv2, YOLOv11, YOLOv8, and YOLOv5 object detectors for computer vision and pattern recognition. arXiv:2510.09653v3. <https://doi.org/10.48550/arXiv.2510.09653>
- Villegas-Ch, W., Maldonado Navarro, A., & Sanchez-Viteri, S. (2024). Optimization of inventory management through computer vision and machine learning technologies. *Intelligent Systems with Applications*, 24, 200438. <https://doi.org/10.1016/j.iswa.2024.200438>
- Wang, C.-Y., Yeh, I.-H., & Liao, H.-Y. M. (2024). YOLOv9: Learning what you want to learn using programmable gradient information. arXiv:2402.13616v2. <https://doi.org/10.48550/arXiv.2402.13616>

Zendehdel, N., Chen, H., & Leu, M. C. (2023). Real-time tool detection in smart manufacturing using You-Only-Look-Once (YOLO)v5. *Manufacturing Letters*, 35, 1052–1059. <https://doi.org/10.1016/j.mfglet.2023.08.091>