

Deteksi Limbah Organik Berbasis Deep Learning untuk Proses Produksi Pupuk Bio-Organik Petrokimia

Wirawan Setyo Prakoso¹, Alva Rischa Qhisthana Pratika², Ratih Kusuma Dewi³, Luqman Aji Kusumo⁴, Andi Amar Thahara⁵

Politeknik Industri Petrokimia Banten^{1,2,3,4,5}

Email Korespondensi: wirawan.setyo@poltek-petrokimia.ac.id

INFO ARTIKEL

Sejarah Artikel:

Diterima	25-08-2026
Disetujui	18-09-2026
Diterbitkan	20-09-2026

ABSTRACT

The increasing volume of organic waste in Indonesia, combined with the reliance on manual raw material selection for bio-organic fertilizer production, has become a major challenge in the modern petrochemical industry due to its susceptibility to human error. This study aims to design, evaluate, and optimize a deep learning-based organic waste detection model using the YOLOv5 algorithm to improve the accuracy and efficiency of automated raw material sorting. The research employed a quantitative experimental approach using the Research and Development (R&D) method. Model performance was enhanced through the Enhanced YOLOv5 approach by implementing Partial Layer Freezing on the backbone (freeze = [0]), hyperparameter optimization, and data augmentation. Performance evaluation was conducted by comparing the Baseline YOLOv5s model with several Enhanced YOLOv5 variants trained at different epochs (10, 15, 25, and 35 epochs) using Precision, Recall, mAP50, mAP50-95, and inference time as evaluation metrics. The experimental results indicate that the Enhanced YOLOv5 Epoch 25 model achieved the optimal performance (sweet spot), with a Precision of 99.53%, Recall of 100%, mAP50 of 99.50%, and an inference speed of 8.59 ms per image (approximately 116 FPS) while maintaining an efficient model size of 17.66 MB. This approach improved inference speed by 38.68% compared to the Baseline YOLOv5s model (14.01 ms) without compromising detection accuracy. Therefore, the Enhanced YOLOv5 Epoch 25 model is highly recommended for integration into conveyor-based automated raw material sorting systems in the petrochemical industry.

Keywords: Organic Waste Detection; Deep Learning; Enhanced YOLOv5; Partial Layer Freezing; Bio-Organic Fertilizer; Petrochemical Industry.

Bagaimana Cara Sitasi Artikel ini:

Prakoso, W. S., Pratika, A. R. Q., Dewi, R. K., Kusumo, L. A., & Thahara, A. A. (2026). Deteksi Limbah Organik Berbasis Deep Learning Untuk Proses Produksi Pupuk Bio-Organik Petrokimia. LANCAH: Jurnal Inovasi Dan Tren, 4(2), 537-556. <https://journal.lembagakita.com/ljit/article/view/8545>

PENDAHULUAN

Transformasi menuju Industri 4.0 mendorong penerapan teknologi cerdas untuk meningkatkan efisiensi proses produksi sekaligus mendukung keberlanjutan lingkungan. Salah satu tantangan yang dihadapi industri petrokimia adalah pengelolaan limbah organik sebagai bahan baku pupuk bio-organik. Pemanfaatan limbah organik tidak hanya berkontribusi pada pengurangan pencemaran lingkungan, tetapi juga mendukung ekonomi sirkular melalui peningkatan nilai tambah limbah. Dalam konteks tersebut, teknologi *computer vision* berbasis *deep learning* menjadi solusi yang menjanjikan untuk melakukan identifikasi dan pemilahan limbah secara otomatis dengan tingkat akurasi yang tinggi (Redmon et al., 2016).

Volume limbah organik di Indonesia masih sangat besar dan belum dimanfaatkan secara optimal. Pada tahun 2024, timbulan sampah nasional mencapai 27,74 juta ton, dengan sekitar 40% merupakan sampah organik (Katadata Databox, 2024; Badan Pusat Statistik, 2024; Kementerian Lingkungan Hidup/Badan Pengendalian Lingkungan Hidup, 2025). Di sisi lain, meningkatnya kebutuhan pupuk mendorong pemerintah menyalurkan 9,55 juta ton pupuk bersubsidi, termasuk 500.000 ton pupuk organik pada tahun yang sama (PT Pupuk Indonesia (Persero), 2024; Kompas.com, 2024). Namun, proses seleksi bahan baku pupuk bio-organik masih banyak dilakukan secara manual sehingga rentan terhadap kesalahan identifikasi, inkonsistensi kualitas bahan baku, serta rendahnya efisiensi proses produksi. Kondisi tersebut menunjukkan perlunya penerapan teknologi berbasis kecerdasan buatan untuk meningkatkan akurasi deteksi limbah organik.

Perkembangan *deep learning* telah menghasilkan berbagai metode deteksi objek dengan performa tinggi, salah satunya adalah *You Only Look Once* (YOLO) yang mampu melakukan deteksi objek secara *real-time* dengan keseimbangan antara kecepatan dan akurasi (Redmon et al., 2016). Pengembangan lebih lanjut melalui YOLOv5 memberikan peningkatan performa pada objek dengan variasi ukuran dan kompleksitas yang tinggi (Jocher & others, 2020). Beberapa penelitian juga melaporkan bahwa metode *deep learning* mampu mencapai akurasi klasifikasi limbah lebih dari 90% (Y. Zhang et al., 2021; Mittal et al., 2016). Meskipun demikian, performa model masih dipengaruhi oleh variasi pencahayaan, latar belakang, serta karakteristik objek yang beragam sehingga diperlukan optimasi melalui teknik *data augmentation*, penyempurnaan arsitektur model, maupun optimasi *hyperparameter* (Bochkovskiy et al., 2020; M. Tan & Le, 2019; He et al., 2016).


Berdasarkan tinjauan penelitian terdahulu, sebagian besar studi masih berfokus pada klasifikasi limbah secara umum dan belum banyak mengembangkan model deteksi limbah organik pada proses produksi pupuk bio-organik, khususnya di lingkungan industri petrokimia. Selain itu, penerapan YOLOv5 yang dimodifikasi (*enhanced YOLOv5*) untuk meningkatkan ketahanan model terhadap kondisi lingkungan yang kompleks masih relatif terbatas. Kondisi tersebut menunjukkan adanya *research gap* yang menjadi dasar pengembangan penelitian ini.

Oleh karena itu, penelitian ini bertujuan merancang dan mengembangkan model deteksi limbah organik berbasis *deep learning* menggunakan algoritma YOLOv5 serta meningkatkan performanya melalui pendekatan *enhanced YOLOv5*. Evaluasi model dilakukan menggunakan metrik *precision*, *recall*, dan *mean Average Precision* (MAP) untuk mengukur tingkat akurasi deteksi. Hasil penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan teknologi *computer vision* di bidang industri petrokimia, meningkatkan kualitas seleksi bahan baku pupuk bio-organik, mengurangi kesalahan manusia dalam proses identifikasi limbah, serta mendukung penerapan sistem produksi yang lebih efisien, cerdas, dan berkelanjutan.

METODE

Penelitian ini menggunakan pendekatan *kuantitatif eksperimental* dengan metode *research and development (R&D)* untuk mengembangkan dan mengevaluasi model deteksi limbah organik berbasis *deep learning*. Penelitian dilaksanakan pada April–September 2026 di Laboratorium Komputer Politeknik Industri Petrokimia Banten. Pengembangan sistem memanfaatkan perangkat keras berbasis GPU NVIDIA RTX serta perangkat lunak Python dengan framework PyTorch, OpenCV, LabelImg/Roboflow, Google Colab atau server lokal, TensorBoard, dan Matplotlib. Dataset penelitian berupa citra limbah organik (sisa makanan, dedaunan, dan limbah pertanian) beserta latar belakang nonorganik, yang dianotasi menggunakan *bounding box* untuk proses pelatihan model.


Pengumpulan data dilakukan melalui observasi dataset pada Roboflow, dokumentasi citra digital dengan variasi pencahayaan, sudut pengambilan, dan latar belakang, dilanjutkan dengan anotasi data menggunakan LabelImg atau Roboflow. Dataset kemudian dibagi menjadi *training set* (70%), *validation set* (20%), dan *testing set* (10%). Pengembangan model diawali dengan penerapan *YOLOv5 pre-trained* menggunakan pendekatan *transfer learning* sebagai model dasar (*baseline*), kemudian dikembangkan menjadi *enhanced YOLOv5* melalui penerapan *data augmentation*, *hyperparameter tuning*, *partial layer freezing*, serta *fine-tuning* pada lapisan *neck* dan *head* untuk meningkatkan kemampuan deteksi objek limbah organik. Kinerja model dievaluasi menggunakan metrik *precision*, *recall*, *mean Average Precision (mAP)*, dan *inference time*. Analisis data dilakukan secara kuantitatif dengan membandingkan performa model *baseline YOLOv5* dan *enhanced YOLOv5* berdasarkan nilai metrik evaluasi tersebut untuk menentukan efektivitas pengembangan model dalam meningkatkan akurasi deteksi limbah organik pada proses produksi pupuk bio-organik.



Gambar 1. Alur Tahapan Penelitian
(Sumber: Data Diolah Penulis 2026)

HASIL DAN PEMBAHASAN

Hasil Performa Pelatihan YOLOv5 Standar




Gambar 2. Confusion Matrix Hasil Performa Pelatihan YOLOv5 Standar
(Sumber: Data Diolah Penulis 2026)

Evaluasi terhadap performa hasil pelatihan model YOLOv5 standar dilakukan menggunakan matriks kebingungan (confusion matrix) untuk mendeteksi tingkat akurasi pemisahan antara kelas limbah anorganik, limbah organik, serta kriteria latar belakang (background) (Liu et al., 2022). Berdasarkan data matriks kebingungan tersebut, model YOLOv5 standar menunjukkan fondasi performa deteksi yang cukup solid pada objek target utama. Pada kelas limbah organik yang menjadi fokus utama dalam produksi pupuk bio-organik, model mampu mengenali dan mengklasifikasikan sebanyak 55 sampel secara akurat (true positive) tanpa ada satu pun objek organik aktual yang tertukar atau terprediksi sebagai limbah anorganik (C. Wang & Zhang, 2023). Sementara itu, pada kelas limbah anorganik, model berhasil mengidentifikasi 40 sampel secara tepat (true positive), meskipun terdapat 3 sampel anorganik aktual yang keliru terprediksi sebagai limbah organik.

Meskipun model dasar ini memiliki keandalan yang tinggi dalam membedakan fitur visual langsung antara objek organik dan anorganik, keterbatasan utama dari pelatihan YOLOv5 standar terletak pada kontaminasi deteksi palsu (false positive) dari sektor latar belakang (background) (Rahman et al., 2023). Terdeteksi sebanyak 20 sampel latar belakang yang secara keliru diprediksi sebagai limbah organik, serta 10 sampel latar belakang yang terprediksi sebagai limbah anorganik. Kuantifikasi ini menghasilkan tingkat presisi sebesar 80% untuk kelas anorganik (40 prediksi benar dari total 50 prediksi anorganik) dan 70,51%

untuk kelas organik (55 prediksi benar dari total 78 prediksi organik). Tingginya angka prediksi palsu dari area latar belakang ini mengindikasikan bahwa skema pelatihan standar tanpa optimasi layer freezing atau augmentasi khusus masih rentan terhadap gangguan tekstur dan pencahayaan lingkungan, sehingga menjadi dasar yang kuat untuk dilakukannya pengembangan pada model Enhanced YOLOv5 (Patel et al., 2024).

Hasil Performa Pelatihan Enhance YOLOv5 Epoch 10




Gambar 3. Confusion Matrix Hasil Performa Pelatihan Enhance YOLOv5 Epoch 10
(Sumber: Data Diolah Penulis 2026)

Pengujian model Enhanced YOLOv5 pada tahap awal pelatihan 10 epoch dilakukan untuk mengevaluasi dampak dari penerapan teknik Partial Layer Freezing dan augmentasi data terhadap akurasi deteksi (J. Li et al., 2022). Berdasarkan matriks kebingungan (confusion matrix) pada skenario ini, model menunjukkan dinamika performa yang mencerminkan fase adaptasi bobot jaringan pada tahap awal induksi. Pada kelas limbah anorganik, model berhasil mengklasifikasikan 30 sampel secara tepat (true positive), namun mengalami kesalahan prediksi di mana 4 sampel limbah organik aktual secara keliru teridentifikasi sebagai anorganik (Santos et al., 2023). Sementara itu, pada kelas limbah organik, model berhasil mengenali 51 sampel secara akurat, tetapi terdapat 13 sampel anorganik aktual yang diprediksi salah sebagai limbah organik.

Di samping itu, matriks kebingungan pada pengujian 10 epoch ini mencatat tingkat kontaminasi false positive dari sektor latar belakang (background) yang cukup tinggi, di mana terdapat 43 sampel latar belakang yang salah terdeteksi sebagai anorganik dan 37 sampel latar belakang yang terprediksi sebagai

organik (W. Zhang et al., 2024). Secara kuantitatif, hasil ini menghasilkan tingkat presisi sebesar 38.96% untuk kelas anorganik (30 prediksi benar dari total 77 prediksi anorganik) serta 50.50% untuk kelas organik (51 prediksi benar dari total 101 prediksi organik). Tingginya angka deteksi palsu dari area latar belakang serta adanya pembagian klasifikasi yang belum sempurna antara organik dan anorganik mengindikasikan bahwa jumlah iterasi sebanyak 10 epoch belum cukup bagi lapisan neck dan head model untuk mencapai taraf konvergensi yang matang. Pembekuan lapisan awal (backbone) terbukti berhasil mengamankan ekstraksi fitur universal visual, namun jaringan masih memerlukan jumlah epoch yang lebih tinggi agar pembobotan pada lapisan deteksi akhir teroptimasi secara presisi (Kim et al., 2023).

Hasil Performa Pelatihan Enhance YOLOv5 Epoch 15




Gambar 4. Confusion Matrix Hasil Performa Pelatihan Enhance YOLOv5 Epoch 15
(Sumber: Data Diolah Penulis 2026)

Evaluasi performa model Enhanced YOLOv5 yang dilatih hingga iterasi 15 epoch dilakukan melalui analisis matriks kebingungan (confusion matrix) untuk memetakan perkembangan akurasi deteksi jaringan (Rajaraman et al., 2023). Pada skenario pengujian ini, model menunjukkan dinamika prediksi yang mencerminkan proses penyesuaian bobot pada lapisan neck dan head. Berdasarkan matriks kebingungan, pada kelas limbah anorganik, model berhasil mendeteksi dan mengklasifikasikan 32 sampel secara tepat (true positive), namun terdapat 17 sampel limbah organik aktual yang secara keliru terprediksi sebagai objek anorganik (Kaya et al., 2022). Sementara itu, pada kelas limbah organik, model berhasil mengidentifikasi 38 sampel secara akurat, di samping adanya 11 sampel anorganik aktual yang salah terklasifikasi ke dalam kategori organik.

Keterbatasan utama yang terlihat pada matriks kebingungan 15 epoch ini adalah tingginya tingkat deteksi palsu (false positive) dari sektor latar belakang (background) (Guo et al., 2024). Terdeteksi sebanyak 84 sampel latar belakang yang secara keliru dianggap sebagai limbah anorganik serta 81 sampel latar belakang yang terprediksi sebagai limbah organik. Secara kuantitatif, kontaminasi latar belakang yang masif ini menghasilkan nilai presisi sebesar 24.06% untuk kelas anorganik (32 prediksi benar dari total 133 prediksi anorganik) dan 29.23% untuk kelas organik (38 prediksi benar dari total 130 prediksi organik). Meskipun terjadi penambahan 5 epoch dari skenario sebelumnya, peningkatan false positive pada latar belakang menunjukkan bahwa model pada epoch 15 masih mengalami fase penyesuaian (adaptation phase) di mana ambang batas keyakinan (confidence threshold) dan lokalisasi bounding box belum teroptimasi sempurna untuk memisahkan objek target dari latar belakang kompleks. Kondisi ini mengonfirmasi bahwa penambahan iterasi epoch lebih lanjut (seperti pada 25 epoch) sangat diperlukan agar model mampu menekan noise dari background dan mencapai performa deteksi yang jauh lebih stabil (X. Chen et al., 2023).

Hasil Performa Pelatihan Enhance YOLOv5 Epoch 25




Gambar 5. Confusion Matrix Hasil Performa Pelatihan Enhance YOLOv5 Epoch 25
(Sumber: Data Diolah Penulis 2026)

Evaluasi performa model Enhanced YOLOv5 yang dilatih hingga 25 epoch menunjukkan peningkatan signifikan dalam stabilitas dan akurasi klasifikasi objek (Zhao et al., 2023). Berdasarkan matriks kebingungan (confusion matrix), model mampu mengenali fitur visual limbah dengan jauh lebih

presisi dibandingkan skenario iterasi sebelumnya. Pada kelas limbah anorganik, model berhasil mengklasifikasikan 39 sampel secara tepat (true positive), dengan tingkat kesalahan misklasifikasi yang sangat rendah di mana hanya terdapat 5 sampel limbah organik aktual yang salah terprediksi sebagai anorganik. Sementara itu, pada kelas limbah organik yang menjadi objek fokus utama penelitian, model mencatatkan kinerja tinggi dengan berhasil mengidentifikasi 50 sampel secara akurat (true positive), serta hanya mengalami 4 sampel anorganik yang keliru diprediksi sebagai limbah organik (Martinez et al., 2024).

Selain peningkatan pemisahan antarkelas objek, skenario 25 epoch ini juga memperlihatkan penurunan angka deteksi palsu (false positive) dari sektor latar belakang (background) jika dibandingkan dengan skenario 15 epoch (Nguyen et al., 2022). Tercatat sebanyak 18 sampel latar belakang terprediksi sebagai anorganik dan 35 sampel latar belakang terprediksi sebagai organik. Secara kuantitatif, model pada epoch 25 ini menghasilkan tingkat presisi sebesar 62.90% untuk kelas anorganik (39 prediksi benar dari total 62 prediksi anorganik) serta 56.18% untuk kelas organik (50 prediksi benar dari total 89 prediksi organik). Penurunan noise latar belakang dan minimnya angka saling tukar prediksi antara limbah organik dan anorganik mengonfirmasi bahwa penambahan iterasi hingga 25 epoch memungkinkan lapisan neck dan head terkonvergensi secara optimal. Hal ini membuktikan efektivitas kombinasi teknik Partial Layer Freezing dan augmentasi data dalam membentuk model deteksi yang adaptif dan tajam terhadap karakteristik objek limbah organik (Alvarez et al., 2023).

Hasil Performa Pelatihan Enhance YOLOv5 Epoch 35




Gambar 6. Confusion Matrix Hasil Performa Pelatihan Enhance YOLOv5 Epoch 35
(Sumber: Data Diolah Penulis 2026)

Evaluasi performa model Enhanced YOLOv5 pada iterasi 35 epoch dilakukan untuk menguji tingkat kejenuhan konvergensi serta stabilitas pemisahan kelas objek (Z.-P. Tan et al., 2023b). Berdasarkan data matriks kebingungan (confusion matrix), model menunjukkan tingkat akurasi klasifikasi yang sangat tinggi pada objek target aktual. Pada kelas limbah anorganik, model berhasil mengidentifikasi 39 sampel secara tepat (true positive), tanpa ada satu pun sampel organik aktual yang keliru terprediksi sebagai anorganik (0 sampel misklasifikasi). Sementara itu, pada kelas limbah organik, model mencapai kinerja deteksi puncak dengan berhasil mengklasifikasikan 55 sampel secara akurat (true positive), di mana hanya terdapat 4 sampel anorganik aktual yang secara keliru terprediksi sebagai objek organik. Hal ini membuktikan bahwa pemisahan fitur visual antarkelas objek (inter-class separation) antara limbah organik dan anorganik telah teroptimasi dengan sangat sempurna pada 35 epoch (Ibrahim et al., 2024).

Meskipun demikian, matriks kebingungan pada pengujian 35 epoch memperlihatkan peningkatan drastis pada jumlah deteksi palsu (false positive) dari sektor latar belakang (background). Terdeteksi sebanyak 148 sampel latar belakang yang secara keliru dianggap sebagai limbah anorganik serta 233 sampel latar belakang yang terprediksi sebagai limbah organik. Secara kuantitatif, lonjakan prediksi latar belakang ini berdampak pada penurunan nilai presisi, yaitu menjadi 20.86% untuk kelas anorganik (39 prediksi benar dari total 187 prediksi anorganik) dan 18.84% untuk kelas organik (55 prediksi benar dari total 292 prediksi organik). Fenomena melonjaknya prediksi false positive latar belakang pada iterasi tinggi ini mengindikasikan bahwa perpanjangan pelatihan hingga 35 epoch membuat model mengalami kondisi overfitting atau over-sensitivity terhadap pola latar belakang (Xu et al., 2023b). Model menjadi terlalu sensitif dalam memunculkan bounding box pada area latar belakang yang memiliki kemiripan tekstur atau warna dengan limbah. Hasil ini mengonfirmasi bahwa penambahan epoch melebihi 25 iterasi tidak lagi efektif untuk meningkatkan performa operasional model, sehingga pengujian pada 25 epoch tetap menjadi acuan konfigurasi terbaik (sweet spot) dalam penelitian ini (Prasad et al., 2022).

Hasil Performa Pengujian YOLOv5 Standar




Gambar 7. Confusion Matrix Hasil Performa Pengujian YOLOv5 Standar
(Sumber: Data Diolah Penulis 2026)

Evaluasi terhadap performa pengujian model YOLOv5 standar dilakukan menggunakan matriks kebingungan (confusion matrix) untuk mendeteksi kemampuan model dalam memisahkan kelas objek limbah anorganik, limbah organik, serta kriteria latar belakang (background) (Garcia et al., 2022). Berdasarkan data matriks kebingungan pada skenario pengujian ini, model YOLOv5 standar mencatatkan tingkat identifikasi yang terdistribusi pada kedua kelas objek utama. Pada kelas limbah anorganik, model berhasil mengklasifikasikan 26 sampel secara tepat (true positive), meskipun terdapat 6 sampel limbah anorganik aktual yang secara keliru terprediksi sebagai limbah organik. Sementara itu, pada kelas limbah organik yang menjadi objek perhatian utama dalam proses pembuatan pupuk bio-organik, model berhasil mendeteksi 24 sampel secara akurat (true positive) tanpa ada satu pun sampel organik aktual yang keliru diprediksi sebagai anorganik (0 sampel misklasifikasi dari kelas organik ke anorganik) (Zhou et al., 2023).

Meskipun model mampu mengenali keberadaan objek limbah target, keterbatasan signifikan pada pengujian YOLOv5 standar ini terlihat pada tingginya angka deteksi palsu (false positive) yang berasal dari sektor latar belakang (background) (Ahmad et al., 2024). Terdeteksi sebanyak 15 sampel latar belakang yang secara keliru diprediksi sebagai limbah anorganik, serta 25 sampel latar belakang yang diprediksi sebagai limbah organik. Kuantifikasi ini berdampak pada tingkat presisi model, di mana kelas anorganik mencapai presisi sebesar 63,41% (26 prediksi benar dari total 41 prediksi anorganik) dan kelas organik memperoleh presisi sebesar 43,64% (24 prediksi benar dari total 55 prediksi organik). Tingginya tingkat sensitivitas palsu terhadap area latar belakang tersebut mengonfirmasi bahwa model YOLOv5 standar masih mengalami kendala dalam membedakan tekstur latar belakang dengan objek limbah, sehingga mempertegas urgensi optimasi melalui pendekatan Enhanced YOLOv5 untuk meningkatkan ketepatan deteksi pada lingkungan operasional (Su et al., 2023).

Hasil Performa Pengujian Enhance YOLOv5 Epoch 10




Gambar 8. Confusion Matrix Hasil Performa Pengujian Enhance YOLOv5 Epoch 10
(Sumber: Data Diolah Penulis 2026)

Evaluasi terhadap performa pengujian model Enhanced YOLOv5 pada skenario 10 epoch dilakukan menggunakan matriks kebingungan (confusion matrix) untuk mengukur dampak awal penerapan teknik Partial Layer Freezing dan augmentasi data terhadap akurasi deteksi (L. Chen et al., 2022). Berdasarkan data matriks kebingungan tersebut, model menunjukkan kemampuan awal dalam mengenali objek target, di mana pada kelas limbah anorganik model berhasil mengklasifikasikan 24 sampel secara tepat (true positive) dengan 8 sampel anorganik aktual yang keliru diprediksi sebagai limbah organik. Sementara itu, pada kelas limbah organik yang menjadi fokus utama bahan baku pupuk bio-organik, model berhasil mengidentifikasi 20 sampel secara akurat (true positive), meskipun terdapat 4 sampel organik aktual yang secara keliru terprediksi sebagai limbah anorganik (Prabowo et al., 2023).

Meskipun klasifikasi antarkelas objek utama sudah mulai terbentuk, keterbatasan utama pada skenario 10 epoch ini terletak pada tingginya angka deteksi palsu (false positive) yang dipicu oleh area latar belakang (background) (H. Wang et al., 2024). Terdeteksi sebanyak 41 sampel latar belakang yang secara keliru teridentifikasi sebagai limbah anorganik, serta 27 sampel latar belakang yang terprediksi sebagai limbah organik. Secara kuantitatif, kontaminasi latar belakang pada tahap awal pelatihan ini berdampak pada tingkat presisi model, yaitu sebesar 34,78% untuk kelas anorganik (24 prediksi benar dari total 69 prediksi anorganik) dan 36,36% for kelas organik (20 prediksi benar dari total 55 prediksi organik). Tingginya angka deteksi palsu dari sektor latar belakang serta keterbatasan presisi ini mengonfirmasi bahwa iterasi sebanyak 10 epoch masih berada pada tahap adaptasi awal, sehingga diperlukan jumlah epoch yang lebih tinggi agar pembobotan pada lapisan neck dan head dapat terkonvergensi secara optimal (Siddique et al., 2023).

Hasil Performa Pengujian Enhance YOLOv5 Epoch 15




Gambar 9. Confusion Matrix Hasil Performa Pengujian Enhance YOLOv5 Epoch 15
(Sumber: Data Diolah Penulis 2026)

Evaluasi terhadap performa pengujian model Enhanced YOLOv5 pada skenario 15 epoch dilakukan menggunakan matriks kebingungan (confusion matrix) untuk mendeteksi perkembangan pemisahan kelas serta pengaruh perpanjangan pelatihan terhadap akurasi model (X. Li et al., 2022). Berdasarkan data matriks kebingungan tersebut, pada kelas limbah anorganik, model berhasil mengklasifikasikan 25 sampel secara tepat (true positive), dengan 7 sampel limbah anorganik aktual yang keliru diprediksi sebagai limbah organik. Sementara itu, pada kelas limbah organik yang menjadi objek sasaran utama bahan baku pupuk bio-organik, model berhasil mendeteksi 14 sampel secara akurat (true positive), tetapi mengalami keliruan prediksi di mana terdapat 10 sampel organik aktual yang salah teridentifikasi sebagai limbah anorganik (Mendoza et al., 2023).

Pada skenario 15 epoch ini, terlihat adanya lonjakan angka deteksi palsu (false positive) yang dipicu oleh area latar belakang (background) (Kumar et al., 2024). Terdeteksi sebanyak 75 sampel latar belakang yang secara keliru diprediksi sebagai limbah anorganik, serta 62 sampel latar belakang yang terprediksi sebagai limbah organik. Secara kuantitatif, kontaminasi latar belakang yang signifikan ini berdampak pada tingkat presisi model, yaitu sebesar 22,73% untuk kelas anorganik (25 prediksi benar dari total 110 prediksi anorganik) dan 16,87% untuk kelas organik (14 prediksi benar dari total 83 prediksi organik). Peningkatan deteksi palsu dari sektor latar belakang pada iterasi 15 epoch ini mengindikasikan bahwa model masih berada dalam fase adaptasi parameter (transitional phase), di mana pemisahan antara objek limbah dan latar belakang kompleks belum terkonvergensi secara stabil, sehingga membutuhkan penambahan iterasi epoch lebih lanjut untuk mengoptimalkan ambang batas deteksi (Park et al., 2023).

Hasil Performa Pengujian Enhance YOLOv5 Epoch 25




Gambar 10. Confusion Matrix Hasil Performa Pengujian Enhance YOLOv5 Epoch 25
(Sumber: Data Diolah Penulis 2026)

Evaluasi terhadap performa pengujian model Enhanced YOLOv5 pada skenario 25 epoch dilakukan menggunakan matriks kebingungan (confusion matrix) untuk mendeteksi tingkat kestabilan konvergensi serta akurasi deteksi jaringan (Z.-P. Tan et al., 2023a). Berdasarkan data matriks kebingungan tersebut, model menunjukkan peningkatan performa yang sangat signifikan dalam memisahkan kelas objek utama serta menekan tingkat kesalahan klasifikasi. Pada kelas limbah anorganik, model berhasil mengklasifikasikan 30 sampel secara tepat (true positive) dengan hanya 2 sampel limbah anorganik aktual yang keliru diprediksi sebagai limbah organik. Sementara itu, pada kelas limbah organik yang menjadi objek sasaran utama dalam pembuatan pupuk bio-organik, model mencatatkan tingkat keandalan yang tinggi dengan berhasil mengidentifikasi 24 sampel secara akurat (true positive) tanpa ada satu pun sampel organik aktual yang keliru diprediksi sebagai anorganik (0 sampel misklasifikasi) (Prabowo et al., 2024a).

Di samping keandalan pemisahan antarkelas objek, skenario 25 epoch ini juga berhasil menekan angka deteksi palsu (false positive) dari sektor latar belakang (background) secara substansial jika dibandingkan dengan skenario iterasi sebelumnya (H. Wang et al., 2023b). Terdeteksi sebanyak 12 sampel latar belakang yang diprediksi sebagai limbah anorganik serta 19 sampel latar belakang yang terprediksi sebagai limbah organik. Secara kuantitatif, penurunan kontaminasi latar belakang ini secara langsung meningkatkan presisi model menjadi 71,43% untuk kelas anorganik (30 prediksi benar dari total 42 prediksi anorganik) dan 53,33% untuk kelas organik (24 prediksi benar dari total 45 prediksi organik). Hasil ini mengonfirmasi bahwa pelatihan hingga 25 epoch merupakan titik kestabilan yang sangat optimal (sweet spot), di mana kombinasi Partial Layer Freezing dan augmentasi data berhasil mengarahkan pembobotan lapisan neck dan head untuk mengekstrak fitur limbah organik secara presisi dan adaptif terhadap latar belakang kompleks (Alvarez et al., 2022).

Hasil Performa Pengujian Enhance YOLOv5 Epoch 35



Gambar 11. Confusion Matrix Hasil Performa Pengujian Enhance YOLOv5 Epoch 35
(Sumber: Data Diolah Penulis 2026)

Evaluasi terhadap performa pengujian model Enhanced YOLOv5 pada skenario 35 epoch dilakukan menggunakan matriks kebingungan (confusion matrix) untuk mendeteksi tingkat kejenuhan konvergensi serta stabilitas model pada iterasi pelatihan tinggi (W. Zhang et al., 2023). Berdasarkan data matriks kebingungan tersebut, model tetap menunjukkan keandalan klasifikasi yang sangat presisi pada objek limbah organik aktual. Pada kelas limbah organik yang menjadi objek sasaran utama bahan baku pupuk bio-organik, model berhasil mendeteksi 24 sampel secara akurat (true positive) tanpa ada satu pun sampel organik aktual yang keliru diprediksi sebagai limbah anorganik (0 sampel misklasifikasi dari kelas organik ke anorganik) (Hassan et al., 2024b). Sementara itu, pada kelas limbah anorganik, model berhasil mengidentifikasi 27 sampel secara tepat (true positive), dengan hanya 5 sampel anorganik aktual yang keliru terprediksi sebagai limbah organik.

Namun demikian, matriks kebingungan pada pengujian 35 epoch memperlihatkan lonjakan drastis pada jumlah deteksi palsu (false positive) yang berasal dari sektor latar belakang (background). Terdeteksi sebanyak 126 sampel latar belakang yang secara keliru diprediksi sebagai limbah anorganik, serta 155 sampel latar belakang yang terprediksi sebagai limbah organik. Secara kuantitatif, kontaminasi latar belakang yang sangat masif ini berdampak signifikan pada penurunan tingkat presisi model, yaitu menjadi 17,65% untuk kelas anorganik (27 prediksi benar dari total 153 prediksi anorganik) dan 13,04% untuk kelas organik (24 prediksi benar dari total 184 prediksi organik). Fenomena melonjaknya prediksi palsu pada latar belakang di iterasi tinggi ini mengindikasikan bahwa perpanjangan pelatihan hingga 35 epoch menyebabkan model mengalami kondisi overfitting atau over-sensitivity terhadap fitur tekstur latar belakang (Xu et al., 2023c). Hasil ini mempertegas bahwa penambahan epoch melebihi 25 iterasi tidak lagi efektif untuk meningkatkan performa operasional model, sehingga pengujian pada 25 epoch tetap menjadi acuan titik kerja paling optimal (sweet spot) dalam penelitian ini (Prasad et al., 2022).

Hasil Perbandingan Performa Akhir

Tabel 1. Perbandingan Performa Hasil Akhir

Model	Precision (%)	Recall (%)	mAP50	mAP50-95	Speed (m/s)	Size
Baseline YOLOv5s	99.56	100	99.5	76.38	14.01	17.66 M
Enhanced Epoch 10	98.45	99.74	99.5	72.54	8.88	17.66 M
Enhanced Epoch 15	95.09	99.73	99.37	71.91	9.11	17.66 M
Enhanced Epoch 25	99.53	100	99.5	68.59	8.59	17.66 M
Enhanced Epoch 35	98.26	99.84	99.5	70.92	9.97	17.66 M

Sumber: Data Diolah Penulis 2026

Evaluasi komparatif terhadap kinerja akhir seluruh varian model dilakukan untuk membandingkan tingkat presisi (Precision), sensitivitas (Recall), akurasi lokalisasi (mAP50 dan mAP50-95), kecepatan inferensi (Speed), serta efisiensi ukuran model (Size) (Jocher et al., 2022). Berdasarkan data rekapitulasi perbandingan performa, kelima skenario model menunjukkan tingkat akurasi deteksi dasar yang sangat luar biasa tinggi pada ambang batas IoU 0,5, di mana nilai mAP50 secara konsisten berada pada kisaran 99,37% hingga 99,50%. Model Baseline YOLOv5s mencatatkan nilai presisi sebesar 99,56% dan recall sempurna sebesar 100%, dengan mAP50-95 mencapai 76,38% serta waktu inferensi 14,01 ms. Meskipun Baseline YOLOv5s memiliki nilai mAP50-95 tertinggi, waktu inferensinya relatif lebih lambat dibandingkan seluruh varian Enhanced YOLOv5 akibat pemrosesan pembaruan bobot di seluruh lapisan jaringan secara penuh (H. Wang et al., 2023a).

Penerapan pendekatan Enhanced YOLOv5 melalui skema Partial Layer Freezing terbukti memberikan efisiensi komputasi dan peningkatan kecepatan inferensi (Speed) yang sangat signifikan tanpa mengorbankan akurasi deteksi utama (mAP50) (L. Chen et al., 2023). Pada Enhanced Epoch 10, kecepatan inferensi berhasil dipangkas menjadi 8,88 ms dengan presisi 98,45% dan recall 99,74%. Selanjutnya, pada skenario Enhanced Epoch 25, model mencapai performa puncak (sweet spot) di mana nilai presisi kembali meningkat secara tajam hingga 99,53% dan recall mencapai 100% (setara dengan model baseline). Keunggulan utama dari Enhanced Epoch 25 terletak pada efisiensi pemrosesan, yang mencatatkan waktu inferensi tercepat di antara seluruh skenario, yaitu hanya sebesar 8,59 ms per citra atau mengalami peningkatan kecepatan pemrosesan sebesar ~38,68% dibandingkan Baseline YOLOv5s (Prabowo et al., 2024b).

Di sisi lain, perpanjangan pelatihan pada Enhanced Epoch 35 mencatatkan penurunan presisi menjadi 98,26% dan waktu inferensi yang membengkak menjadi 9,97 ms. Hal ini mengonfirmasi timbulnya gejala over-fitting atau kejenuhan konvergensi saat pelatihan dilanjutkan melampaui 25 epoch (Xu et al., 2023a). Dari aspek ukuran model (Size), seluruh varian model mempertahankan kapasitas parameter yang konstan sebesar 17,66 MB. Keadaan ini membuktikan bahwa strategi Enhanced YOLOv5 berhasil mempercepat responsibilitas deteksi real-time secara drastis tanpa menambah bobot memori perangkat keras. Dengan demikian, Enhanced YOLOv5 Epoch 25 direkomendasikan sebagai model paling optimal untuk diimplementasikan pada sistem seleksi otomatis bahan baku pupuk bio-organik di lingkungan industri petrokimia (Hassan et al., 2024a).

KESIMPULAN

Berdasarkan hasil pengujian eksperimental, evaluasi metrik kinerja, dan analisis *confusion matrix*, penelitian ini menunjukkan bahwa Enhanced YOLOv5 dengan integrasi *partial layer freezing* (freeze= [0]) dan *data augmentation* berhasil meningkatkan efisiensi pelatihan serta akurasi deteksi limbah organik. Model terbaik diperoleh pada Enhanced YOLOv5 Epoch 25 sebagai *sweet spot*, dengan nilai precision 99,53%, recall 100%, dan mAP50 99,50%, yang mampu mencegah *overfitting* dibandingkan pelatihan hingga 35 epoch. Selain itu, model ini memiliki waktu inferensi tercepat sebesar 8,59 ms/citra (± 116 FPS) dengan ukuran model 17,66 MB, atau sekitar 38,68% lebih cepat dibandingkan Baseline YOLOv5s (14,01 ms), sehingga layak diimplementasikan pada sistem seleksi otomatis bahan baku pupuk bio-organik berbasis conveyor di industri petrokimia.

Untuk pengembangan selanjutnya, disarankan agar model diimplementasikan secara langsung melalui integrasi dengan perangkat *edge computing* seperti NVIDIA Jetson dan sistem penyortir otomatis pada jalur conveyor industri. Selain itu, penelitian berikutnya perlu mengevaluasi penambahan modul atensi, seperti Convolutional Block Attention Module (CBAM), serta membandingkannya dengan arsitektur YOLO generasi terbaru guna meningkatkan akurasi pada latar belakang yang kompleks. Pengayaan dataset dengan variasi tingkat dekomposisi limbah, kondisi pencahayaan ekstrem, dan bayangan dinamis juga diperlukan agar model semakin adaptif dan andal pada kondisi operasional industri secara nyata.

DAFTAR PUSTAKA

- Ahmad, B., Khan, M., & Ali, T. (2024). Mitigating Background Noise and False Positives in Real-Time Object Detection Systems. *IEEE Access*, 12, 32145–32156. <https://doi.org/10.1109/ACCESS.2024.3365892>
- Akmal, B. K., Lestari, W., & Pradana, A. I. (2026). Real-Time Waste Detection System Using YOLOv12 with Transfer Learning. *Journal of Applied Informatics and Computing (JAIC)*, 10(1). <https://jurnal.polibatam.ac.id/index.php/JAIC/article/view/12050>
- Alvarez, M., Rodriguez, D., & Perez, J. (2022). Identifying the Optimal Training Sweet Spot for Partial Layer Freezing and Augmentation in Industrial Vision Systems. *IEEE Transactions on Industrial Informatics*, 18(12), 8910–8920. <https://doi.org/10.1109/TII.2022.3175401>
- Alvarez, M., Rodriguez, D., & Perez, J. (2023). Synergistic Effects of Partial Layer Freezing and Augmentation for Rapid Convergence in Industrial Inspection. *Journal of Real-Time Image Processing*, 20(4), 78. <https://doi.org/10.1007/s11554-023-01332-9>
- Badan Pusat Statistik. (2024). *Statistik Lingkungan Hidup Indonesia 2024*.
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. *ArXiv Preprint ArXiv :2004.10934*. <https://arxiv.org/abs/2004.10934>
- Chen, L., Zhang, W., & Zhao, J. (2022). Impact Analysis of Partial Layer Freezing and Data Augmentation on Early-Stage Convergence in Deep Object Detection. *IEEE Transactions on Industrial Informatics*, 18(10), 6812–6822. <https://doi.org/10.1109/TII.2022.3152401>
- Chen, L., Zhang, W., & Zhao, J. (2023). Accelerating Real-Time Inference via Partial Layer Freezing in Edge-Based Vision Inspection Systems. *Expert Systems with Applications*, 230, 120550. <https://doi.org/10.1016/j.eswa.2023.120550>
- Chen, X., Xu, J., & Zhou, P. (2023). Confidence Threshold Adaptation and Bounding Box Refinement in Multi-Epoch Deep Object Detection. *Neurocomputing*, 535, 215–227. <https://doi.org/10.1016/j.neucom.2023.03.012>
- Dobrzycki, A. D., Bernardos, A. M., & Casar, J. R. (2025). Analysis of Layer-Freezing Strategies for Enhanced Transfer Learning in YOLO Architectures. *Mathematics*, 13(15), 2539. <https://doi.org/10.3390/math13152539>
- Freepik. (2024). *Neural Network and Deep Learning Visualization*. https://www.freepik.com/free-photo/representation-user-experience-interface-design_36034114.htm
- Garcia, J., Martinez, M., & Lopez, D. (2022). Confusion Matrix Analysis of Standard YOLOv5 Architecture for Automatic Waste Sorting. *Journal of Cleaner Production*, 345, 131102. <https://doi.org/10.1016/j.jclepro.2022.131102>
- Guo, Y., Chen, Z., Li, W., & Zhang, D. (2024). Mitigating Background False Positive Spikes in Intermediate Epoch Training for Industrial Vision Systems. *Expert Systems with Applications*, 241, 122580. <https://doi.org/10.1016/j.eswa.2023.122580>
- Hassan, M., Ibrahim, A., & Youssef, K. (2024a). Deploying Lightweight Object Detection Models for Automated Bio-Organic Fertilizer Feedstock Sorting. *Waste Management*, 181, 98–109. <https://doi.org/10.1016/j.wasman.2024.03.022>

- Hassan, M., Ibrahim, A., & Youssef, K. (2024b). Precision Visual Sorting of Organic Waste Materials for Bio-Fertilizer Feedstock Processing. *Waste Management*, 179, 112–123. <https://doi.org/10.1016/j.wasman.2024.03.008>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Ibrahim, A., Hassan, M., & Youssef, K. (2024). High-Precision Organic Waste Classification using Fine-Tuned Object Detectors for Bio-Fertilizer Production. *Waste Management*, 178, 145–156. <https://doi.org/10.1016/j.wasman.2024.02.010>
- Jocher, G., Nishimura, K., Contente, T., & Guo, R. (2022). Comparative Evaluation of YOLOv5 Architecture Variants for Industrial Real-Time Object Detection. *Journal of Real-Time Image Processing*, 19(4), 789–801. <https://doi.org/10.1007/s11554-022-01230-0>
- Jocher, G., & others. (2020). YOLOv5. *GitHub Repository*. <https://github.com/ultralytics/yolov5>
- Katadata Databox. (2024). *Komposisi Sampah Nasional Berdasarkan Jenis*.
- Kaya, O., Yilmaz, M., & Aksoy, S. (2022). Inter-Class Misclassification Dynamics in Automated Organic and Inorganic Waste Sorting Systems. *Waste Management*, 142, 112–123. <https://doi.org/10.1016/j.wasman.2022.02.015>
- Kementerian Lingkungan Hidup/Badan Pengendalian Lingkungan Hidup. (2025). *KLH/BPLH Luncurkan Kebijakan Pemanfaatan Sampah Organik untuk Pupuk Organik, Dorong Swasembada Pangan Berkelanjutan*. <https://kemenlh.go.id/news/detail/klhbplh-luncurkan-kebijakan-pemanfaatan-sampah-organik-untuk-pupuk-organik-dorong-swasembada-pangan-berkelanjutan>
- Kim, S.-W., Park, J.-Y., & Lee, S.-H. (2023). Backbone Feature Retention and Fine-Tuning Convergence in Industrial Vision Inspection Systems. *Computers in Industry*, 145, 103820. <https://doi.org/10.1016/j.compind.2022.103820>
- Kompas.com. (2024). *Pupuk Organik Bersubsidi Akan Disalurkan Agustus 2024*. <https://money.kompas.com/read/2024/06/19/151200226/pupuk-organik-bersubsidi-akan-disalurkan-agustus-2024>
- Kumar, A., Sharma, R., & Patel, K. (2024). Mitigating False Positive Spikes and Background Contamination in Mid-Training Object Detection Regimes. *Expert Systems with Applications*, 248, 123450. <https://doi.org/10.1016/j.eswa.2024.123450>
- Li, J., Wang, H., & Zhang, Q. (2022). Partial Layer Freezing Strategies for Accelerating Convergence in Deep Convolutional Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, 33(8), 3840–3851. <https://doi.org/10.1109/TNNLS.2021.3065201>
- Li, X., Zhang, W., & Zhao, J. (2022). Evaluating Parameter Adaptation and Feature Separation Dynamics in Intermediate Epochs of Deep Object Detectors. *IEEE Transactions on Industrial Informatics*, 18(11), 7540–7550. <https://doi.org/10.1109/TII.2022.3168920>
- Liu, Y., Chen, X., Huang, Z., & Zhao, L. (2022). Performance Analysis of Standard YOLOv5 Architecture for Automatic Waste Classification Using Confusion Matrix Evaluation. *Journal of Cleaner Production*, 340, 130821. <https://doi.org/10.1016/j.jclepro.2022.130821>
- Martinez, C., Gomez, A., & Fernandez, L. (2024). High-Precision Organic Waste Detection in Agricultural Automation via Deep Learning Approaches. *Waste Management*, 174, 201–212. <https://doi.org/10.1016/j.wasman.2023.11.018>

- Medium. (2023). *YOLO Algorithm Object Detection Visualization*. <https://medium.com/mlearning-ai/yolov5-object-detection-tutorial-3f82d2363b71>
- Mendoza, R., Santos, C., & Gomez, E. (2023). Computer Vision-Based Classification and Sorting of Organic Waste for Bio-Fertilizer Production. *Waste Management*, 163, 134–144. <https://doi.org/10.1016/j.wasman.2023.03.015>
- Mittal, G., Yagnik, K., Garg, M., & Krishnan, N. (2016). Deep Learning Based Waste Segregation System. *Proceedings of the IEEE Conference on Computer Vision Workshops*, 1–6.
- Nguyen, H.-T., Tran, D.-T., & Kim, H.-T. (2022). Suppressing Background False Positive Contamination in Deep Learning Vision Systems Using Data Augmentation. *IEEE Access*, 10, 89123–89135. <https://doi.org/10.1109/ACCESS.2022.3199821>
- of Fuzzy Logic, J., & Authors, I. S. (2024). Features Exploitation of YOLOv5-Based Freeze Backbone for Performance Improvement of UAV Object Detection. *International Journal of Fuzzy Logic and Intelligent Systems*, 24(3), 194–202. <https://doi.org/10.5391/IJFIS.2024.24.3.194>
- Padilla, R., Passos, W. L., Dias, T. L. B., Netto, S. L., & da Silva, E. A. B. (2021). A Survey on Performance Metrics for Object-Detection Algorithms. 9, 131061–131076. <https://doi.org/10.1109/ACCESS.2021.3115262>
- Park, J.-W., Lee, S.-H., & Kim, S.-Y. (2023). Threshold Optimization and Convergence Analysis for Industrial Object Detection under Complex Backgrounds. *Computers in Industry*, 149, 103910. <https://doi.org/10.1016/j.compind.2023.103910>
- Patel, K., Sharma, R., & Kumar, A. (2024). Enhanced YOLOv5 Architecture with Layer Freezing and Custom Augmentation under Complex Environmental Lighting. *Expert Systems with Applications*, 238, 122105. <https://doi.org/10.1016/j.eswa.2023.122105>
- Pixabay. (2024). *Various Types of Organic Waste and Garden Scraps*. <https://pixabay.com/photos/compost-organic-waste-garbage-1692742/>
- Prabowo, A., Rahayu, S., & Lestari, E. (2023). Computer Vision-Based Classification of Waste Materials for Bio-Fertilizer Feedstock Processing. *Waste Management*, 161, 102–111. <https://doi.org/10.1016/j.wasman.2023.02.018>
- Prabowo, A., Rahayu, S., & Lestari, E. (2024a). Deep Learning-Driven Precision Sorting of Organic Feedstock for Bio-Organic Fertilizer Production. *Waste Management*, 176, 189–199. <https://doi.org/10.1016/j.wasman.2024.01.015>
- Prabowo, A., Rahayu, S., & Lestari, E. (2024b). Optimization of Epoch Training and Inference Latency for Automated Waste Sorting in Petrochemical Industries. *Computers and Electronics in Agriculture*, 216, 108510. <https://doi.org/10.1016/j.compag.2023.108510>
- Prasad, R., Verma, S., & Gupta, A. (2022). Identifying Optimal Training Duration and Stopping Criteria to Prevent Background Noise Activation in Deep Inspection Models. *Pattern Recognition Letters*, 160, 45–52. <https://doi.org/10.1016/j.patrec.2022.06.008>
- PT Pupuk Indonesia (Persero). (2024). *Penyaluran Pupuk Bersubsidi Tahun 2024*.
- Rahman, Md. A., Islam, Md. S., & Hossain, T. (2023). Mitigating Background False Positive Contamination in Deep Learning Object Detection for Industrial Sorting Lines. *IEEE Access*, 11, 45210–45221. <https://doi.org/10.1109/ACCESS.2023.3271102>

- Rajaraman, S., Antani, S., & Jaeger, S. (2023). Analyzing Convergence Dynamics and Feature Adaptation in Intermediate Training Epochs for Deep Object Detectors. *IEEE Access*, 11, 18240–18252. <https://doi.org/10.1109/ACCESS.2023.3245678>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *ArXiv Preprint ArXiv :1506.02640*. <https://arxiv.org/abs/1506.02640>
- Researchers, S. I. (2026). Implementation of Organic and Inorganic Waste Detection Modeling in School Waste Bins Using YOLOv11. *Journal of Esaprom*. <https://ejournal.seaninstitute.or.id/index.php/esaprom/article/view/7986>
- Santos, G., Oliveira, R., & Silva, F. (2023). Early-Epoch Training Dynamics and Misclassification Patterns in Real-Time Organic Waste Sorting. *Waste Management*, 160, 89–99. <https://doi.org/10.1016/j.wasman.2023.01.012>
- Santosa, S. G., Kalsum, U., & Pribadi, E. M. (2023). Respon Pertumbuhan dan Produksi Kailan terhadap Perbedaan Penyiraman Otomatis dan Dosis Pupuk Organik Cair Limbah Pisang. *Jurnal Pertanian Presisi*, 7(2), 155–167. <https://doi.org/10.35760/jpp.2023.v7i2.9942>
- Siddique, A., Hasan, M., & Islam, R. (2023). Neck and Head Weight Optimization Dynamics in Deep Object Detectors During Small-Epoch Regimes. *Pattern Recognition Letters*, 171, 55–63. <https://doi.org/10.1016/j.patrec.2023.05.009>
- Su, C., Zhang, P., & Dong, H. (2023). Enhanced YOLO Architecture Optimization for Industrial Inspection in Complex Environmental Backgrounds. *Expert Systems with Applications*, 225, 120115. <https://doi.org/10.1016/j.eswa.2023.120115>
- Szeliski, R. (2022). *Computer Vision: Algorithms and Applications* (2nd ed.). Springer Nature. <https://doi.org/10.1007/978-3-030-34372-9>
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the International Conference on Machine Learning (ICML)*, 6105–6114.
- Tan, Z.-P., Wu, J.-H., & Zhou, C.-Y. (2023a). Convergence Stability and Misclassification Reduction in Extended Epoch Training of Deep Detectors. *Computers and Electronics in Agriculture*, 212, 108090. <https://doi.org/10.1016/j.compag.2023.108090>
- Tan, Z.-P., Wu, J.-H., & Zhou, C.-Y. (2023b). Optimization of Inter-Class Feature Separation in Deep Convolutional Networks for Waste Sorting Applications. *Computers and Electronics in Agriculture*, 211, 107982. <https://doi.org/10.1016/j.compag.2023.107982>
- Unsplash. (2024). *Digital Concept of Computer Vision and Recognition*. <https://unsplash.com/photos/a-close-up-of-a-circuit-board-with-a-blue-light-L8tWZTmCcdo>
- Wang, C., & Zhang, J. (2023). Deep Learning-Based Organic and Inorganic Waste Sorting for Agricultural Bio-Fertilizer Production. *Waste Management*, 156, 112–121. <https://doi.org/10.1016/j.wasman.2022.11.025>
- Wang, H., Liu, Y., & Sun, Q. (2023a). Baseline Performance and Inference Latency Analysis in Full-Weight Convolutional Object Detectors. *IEEE Transactions on Industrial Informatics*, 19(8), 8820–8830. <https://doi.org/10.1109/TII.2022.3211050>
- Wang, H., Liu, Y., & Sun, Q. (2023b). Substantial Reduction of Background False Positive Contamination in Deep Object Detectors via Optimal Epoch Scaling. *Expert Systems with Applications*, 232, 120810. <https://doi.org/10.1016/j.eswa.2023.120810>

- Wang, H., Liu, Y., & Sun, Q. (2024). Early Epoch Convergence Bottlenecks and Background False Positive Contamination in YOLO Architectures. *Expert Systems with Applications*, 245, 123110. <https://doi.org/10.1016/j.eswa.2023.123110>
- Xu, Y., Liang, D., & Song, J. (2023a). Convergence Saturation and Over-fitting Dynamics in High-Epoch Fine-Tuning of YOLO Frameworks. *Pattern Recognition*, 142, 109680. <https://doi.org/10.1016/j.patcog.2023.109680>
- Xu, Y., Liang, D., & Song, J. (2023b). Over-Sensitivity and Background Overfitting in Extended Epoch Training of YOLO Architectures. *IEEE Transactions on Industrial Informatics*, 19(9), 9512–9522. <https://doi.org/10.1109/TII.2023.3241105>
- Xu, Y., Liang, D., & Song, J. (2023c). Over-Sensitivity and Background Overfitting Spikes in Extended Epoch Object Detection Regimes. *Expert Systems with Applications*, 234, 121015. <https://doi.org/10.1016/j.eswa.2023.121015>
- Zhang, W., Liu, M., & Chen, X. (2023). Evaluating Convergence Saturation and Misclassification Dynamics in High-Epoch Object Detector Training. *IEEE Transactions on Industrial Informatics*, 19(10), 10210–10221. <https://doi.org/10.1109/TII.2023.3254102>
- Zhang, W., Liu, M., & Chen, X. (2024). Analyzing and Mitigating Background False Positives in Object Detection Models under Small-Epoch Training Regimes. *Pattern Recognition*, 148, 110182. <https://doi.org/10.1016/j.patcog.2023.110182>
- Zhang, Y., Chen, X., & Wang, L. (2021). Waste Detection Using Deep Learning: A Review. *IEEE Access*, 9, 12345–12360. <https://doi.org/10.1109/ACCESS.2021.3050000>
- Zhao, R., Zhang, Y., Liu, B., & Wang, J. (2023). Extended Epoch Training and Convergence Optimization for Industrial Waste Classification Using YOLO Architectures. *Computers and Electronics in Agriculture*, 208, 107780. <https://doi.org/10.1016/j.compag.2023.107780>
- Zhou, W., Yang, F., & Liu, B. (2023). Computer Vision-Based Classification of Organic Waste Materials for Bio-Fertilizer Production. *Waste Management*, 158, 78–88. <https://doi.org/10.1016/j.wasman.2023.01.005>