

DETEKSI HAMA FALL ARMYWORM PADA TANAMAN JAGUNG MENGGUNAKAN YOLO DI DESA OESAO, KABUPATEN KUPANG, NUSA TENGGARA TIMUR

Daniel Wilhelm Valentino Likadja, Derwin Rony Sina, Bertha S.Djahi

Program Studi Ilmu Komputer, Fakultas Sains dan Teknik, Universitas Nusa Cendana

Jalan Adisucipto, Penfui, Kota Kupang, Nusa Tenggara Timur, Indonesia

likadjadave@gmail.com

ABSTRAK

Produksi jagung di Nusa Tenggara Timur mengalami penurunan kumulatif lebih dari 26% dalam empat tahun terakhir, salah satunya akibat serangan hama invasif *Fall Armyworm* (*Spodoptera frugiperda*) yang berpotensi menurunkan hasil panen hingga 70–80%, sementara metode pemantauan konvensional yang bersifat subjektif dan tidak efisien belum mampu menjawab kebutuhan deteksi dini secara akurat pada pertanian skala kecil. Penelitian ini bertujuan mengevaluasi kemampuan deteksi hama *Fall Armyworm* dan gejala kerusakannya pada daun jagung menggunakan lima varian algoritma You Only Look Once (YOLO) generasi terbaru dalam kondisi lapangan nyata. Dataset terdiri dari 2.000 gambar berlabel dua kelas, larva (*Hama Fall_armyworm*) dan pola kerusakan daun (*fall_armyworm damage*), yang dikumpulkan langsung dari lahan Desa Oesao dan diperkaya melalui platform Roboflow, kemudian dilatih dan dievaluasi pada YOLOv8n, YOLOv9t, YOLOv10n, YOLOv11n, dan YOLOv12n menggunakan metrik *Precision*, *Recall*, *F1-Score*, dan *mean Average Precision* (mAP). YOLOv11n mencapai performa terbaik dengan *F1-Score* 61,1% dan mAP@0,5 58,5%, namun seluruh model menunjukkan kesenjangan deteksi signifikan antara kelas larva (mAP@0,5: 0,974–0,988) dan kelas kerusakan daun (mAP@0,5: 0,164–0,240) yang disebabkan oleh ketidakseimbangan distribusi data dan tingginya variasi visual pola kerusakan. Kebaruan arsitektur tidak menjamin performa superior pada dataset berukuran kecil, sehingga perluasan data dan penanganan ketidakseimbangan kelas menjadi prioritas utama penelitian mendatang.

Kata kunci : *Fall Armyworm, Jagung, YOLO, Deteksi Objek, Deep Learning, Desa Oesao*

1. PENDAHULUAN

Jagung (*Zea mays* L.) merupakan tanaman pangan utama di Provinsi Nusa Tenggara Timur (NTT), Indonesia, yang menopang pendapatan pertanian regional sekaligus ketahanan pangan rumah tangga [1], [2]. Berdasarkan data Badan Pusat Statistik NTT (BPS-NTT), produksi jagung provinsi mengalami penurunan dari 884.328 ton pada tahun 2019 menjadi 698.023 ton pada tahun 2022 dan selanjutnya menjadi 648.305 ton pada tahun 2023. Penurunan kumulatif lebih dari 26% dalam empat tahun [2].

Tren penurunan ini sangat mengkhawatirkan mengingat sekitar 80% rumah tangga pedesaan di provinsi ini menggantungkan penghidupan utama mereka pada budidaya jagung. *Fall Armyworm*, merupakan hama invasif yang bersifat sangat polifag, pertama kali dilaporkan di Afrika Sub-Sahara pada tahun 2016 dan kemudian menyebar cepat ke seluruh Asia, termasuk Indonesia [3].

Pada sistem pertanian lahan kering NTT[4]. *Fall Armyworm* menimbulkan ancaman yang sangat serius: kehilangan hasil yang terdokumentasi berkisar antara 70 hingga 80% pada serangan berat [5], [6].

Larva menyerang hampir seluruh organ tanaman di atas permukaan tanah—daun muda, whorl, bunga jantan, dan tongkol menghasilkan perforasi tidak beraturan yang khas, deposit frass, serta kerusakan whorl yang dapat berujung pada gagal panen total apabila tidak dikelola [6].

Pengelolaan hama konvensional mengandalkan pengamatan visual oleh tenaga terampil, suatu proses yang memakan waktu, bersifat subjektif, dan tidak praktis dalam skala luas untuk sistem pertanian skala kecil. Selain itu, deteksi yang tidak presisi sering kali memicu penggunaan pestisida berlebihan dan tidak terarah, yang memperburuk kekhawatiran lingkungan dan kesehatan masyarakat di komunitas pedesaan [7].

Kemajuan dalam *computer vision* dan *deep learning* menawarkan jalur yang menjanjikan menuju deteksi hama otomatis secara *real-time* menggunakan perangkat berbiaya rendah seperti kamera *smartphone* [8], [9]. Kerangka deteksi objek berbasis *convolutional neural network* (CNN) telah banyak diterapkan untuk pengenalan penyakit dan hama tanaman [10], [11].

Di antara kerangka tersebut, keluarga algoritma You Only Look Once (YOLO), yang melakukan deteksi dan klasifikasi dalam satu lintasan maju (*single forward pass*) dengan memprediksi *bounding box*, *confidence score*, dan probabilitas kelas secara simultan menonjol karena keseimbangannya antara kecepatan inferensi dan akurasi, sehingga sangat cocok untuk penerapan di lapangan [12] pada perangkat dengan sumber daya terbatas [12], [13].

Studi klasifikasi berbasis CNN sebelumnya pada dataset satu kelas yang terkontrol melaporkan akurasi klasifikasi tingkat citra yang melebihi 90% namun, pendekatan tersebut tidak dapat melokalisasi beberapa objek yang muncul bersamaan dalam citra lapangan terbuka [14], [15].

Suatu tugas yang jauh lebih menantang namun sangat relevan secara praktis untuk pengamatan hama di lapangan nyata. Meskipun minat terhadap perlindungan tanaman berbantuan kecerdasan buatan terus berkembang, perbandingan sistematis terhadap generasi YOLO terbaru secara spesifik untuk deteksi Fall Armyworm di bawah kondisi lapangan tropis yang menantang, menggunakan data primer yang dikumpulkan secara lokal, masih belum tersedia dalam literatur. Penelitian seperti Kanna et al dan Ahmed mendemonstrasikan efektivitas YOLO pada benchmark pertanian umum, namun tidak ada yang dilatih pada data primer dari lahan petani kecil Indonesia atau menargetkan deteksi Fall Armyworm dual-kelas (larva dan kerusakan daun secara simultan). [12], [13]

Penelitian ini menutup kesenjangan tersebut dengan mengevaluasi lima arsitektur YOLO (YOLOv8n, YOLOv9t, YOLOv10n, YOLOv11n, dan YOLOv12n) pada tugas deteksi Fall Armyworm dual-kelas menggunakan citra jagung yang dikumpulkan langsung dari Desa Oesao, Kabupaten Kupang, NTT. Tujuan spesifik penelitian ini adalah: (1) menilai performa deteksi setiap model menggunakan metrik *Precision*, *Recall*, *F1-Score*, dan *mAP*; dan (2) mengidentifikasi arsitektur yang paling sesuai untuk pemantauan Fall Armyworm di lapangan di Indonesia bagian timur.

2. TINJAUAN PUSTAKA

Pemetaan terhadap penelitian terdahulu menjadi langkah krusial dalam membangun landasan ilmiah yang kokoh sekaligus memastikan kontribusi orisinal dari studi yang dikembangkan. Sejumlah penelitian sebelumnya di bidang deteksi hama dan penyakit tanaman jagung telah mengeksplorasi berbagai pendekatan, mulai dari klasifikasi citra berbasis *machine learning*, penerapan algoritma deteksi objek, hingga pemanfaatan kecerdasan buatan sebagai solusi dalam mendukung pertanian presisi.

2.1. Penelitian Terdahulu

Beragam arsitektur deep learning telah dikembangkan untuk deteksi dan klasifikasi hama/penyakit tanaman, mendukung pertanian presisi.

a. Survei Deep Learning untuk Pertanian

Pada penelitian yang berjudul "*Deep Learning in Agriculture: A Survey*" yang dilakukan oleh Kamilaris dan Prenafeta-Boldú [16], disimpulkan bahwa CNN secara konsisten mengungguli metode *machine learning* tradisional pada tugas klasifikasi citra tanaman. Studi ini menjadi landasan penting bagi pengembangan sistem deteksi berbasis citra di sektor pertanian, meskipun bersifat tinjauan umum dan tidak menguji kasus hama spesifik.

b. Deteksi Penyakit dan Hama Tanaman Berbasis Deep Learning

Pada penelitian yang berjudul "*Plant Diseases and Pests Detection Based on Deep Learning: A Review*" yang dilakukan oleh Liu dan Wang [11],

didokumentasikan pergeseran paradigma dari pendekatan klasifikasi CNN menuju deteksi objek berbasis YOLO yang memungkinkan lokalisasi spasial serangan hama secara *real-time*. Studi ini menegaskan bahwa CNN klasifikasi murni tidak mampu mendeteksi beberapa objek secara bersamaan dalam satu citra lapangan terbuka.

c. Klasifikasi Penyakit Daun Jagung Menggunakan CNN

Pada penelitian yang berjudul "*Klasifikasi Penyakit Daun Jagung Menggunakan Convolutional Neural Network (CNN)*" yang dilakukan oleh Hidayat [17], dikembangkan sistem klasifikasi penyakit daun jagung menggunakan arsitektur CNN dengan hasil akurasi sebesar 94%. Meskipun hasilnya menjanjikan, pendekatan ini terbatas pada klasifikasi citra tunggal tanpa lokalisasi objek, sehingga tidak dapat diterapkan pada skenario pemantauan lapangan multi-objek.

d. Deteksi Penyakit Tanaman Pisang Berbasis Android

Pada penelitian yang berjudul "*Pengembangan Aplikasi Deteksi Penyakit Tanaman Pisang Menggunakan CNN Berbasis Android*" yang dilakukan oleh Sari [14], dikembangkan sistem deteksi penyakit tanaman pisang berbasis CNN pada platform Android dengan akurasi sebesar 100%. Namun pendekatan ini hanya mengidentifikasi satu kategori per citra tanpa menghasilkan *bounding box*, sehingga tidak dapat diterapkan pada skenario pemantauan lapangan multi-objek.

e. Dataset RGB dan Termal untuk Deteksi Fall Armyworm

Pada penelitian yang berjudul "*Thermal and RGB Image Dataset for Detection and Management of Fall Army Worm (FAW) Infestation in Maize*" yang dilakukan oleh Sandhya [18], dikembangkan dataset citra RGB dan termal untuk mendukung deteksi dan pengelolaan infestasi Fall Armyworm pada tanaman jagung. Penelitian ini mengamati bahwa pola kerusakan Fall Armyworm bersifat sangat konteks-dependen dan heterogen secara visual, terutama di bawah variasi pencahayaan dan kerumitan latar belakang. Studi ini tidak melakukan perbandingan antar generasi YOLO dan tidak menggunakan data primer dari lapangan pertanian Indonesia bagian timur.

f. Tinjauan Sistematis YOLO untuk Deteksi Objek Pertanian

Pada penelitian yang berjudul "*YOLO Deep Learning Algorithm for Object Detection in Agriculture: A Review*" yang dilakukan oleh Kanna [13], ditemukan bahwa YOLO efektif untuk berbagai tugas deteksi objek pertanian dengan waktu inferensi rendah dan performa stabil pada berbagai kondisi pencahayaan. Namun tinjauan ini bersifat umum dan tidak melakukan pengujian langsung antar generasi YOLO pada satu dataset spesifik.

g. Deteksi Objek *Real-Time* Berbasis YOLO pada *Edge Device*

Pada penelitian yang berjudul "*Yolo-Based Fast and Accurate Object Detection for Real-Time Applications*" yang dilakukan oleh Ahmed [12], dikonfirmasi bahwa arsitektur YOLO relatif ringan dan dapat diimplementasikan pada *edge device* seperti *single-board computer* dan perangkat IoT. Temuan ini memperkuat relevansi pemilihan YOLO dalam penelitian ini mengingat konteks penerapan pada pertanian skala kecil di NTT dengan keterbatasan infrastruktur.

h. Perbandingan YOLOv8, YOLOv9, YOLOv10, YOLOv11, dan Faster R-CNN untuk Deteksi Gulma

Pada penelitian yang berjudul "*Comparative Performance of YOLOv8, YOLOv9, YOLOv10, YOLOv11 and Faster R-CNN Models for Detection of Multiple Weed Species*" yang dilakukan oleh Sharma [19], dilakukan perbandingan lima arsitektur *object detection* pada *dataset* gulma multi-spesies. Hasil evaluasi menunjukkan bahwa YOLOv9 mengungguli YOLOv10 pada *dataset* domain-spesifik berukuran sebanding, memperkuat pandangan bahwa kebaruan arsitektur bukan prediktor performa yang dapat diandalkan ketika data pelatihan terbatas. Studi ini tidak mencakup YOLOv12 maupun konteks lapangan Indonesia..

2.2. Arsitektur YOLO dan Perkembangannya

Algoritma YOLO melakukan deteksi dalam satu lintasan maju dengan membagi citra menjadi kisi-kisi sel dan memprediksi bounding box, confidence score, serta probabilitas kelas secara simultan[12]. Secara arsitektural, seluruh varian YOLO modern berbagi tiga komponen utama: (1) backbone *Cross-Stage Partial* (CSP) untuk ekstraksi fitur hierarkis; (2) neck berupa *Feature Pyramid Network* (FPN) yang digabungkan dengan *Path Aggregation Network* (PAN) untuk fusi fitur multi-skala; dan (3) detection head yang terpisah (*decoupled*) untuk *regresi bounding box* dan prediksi kelas secara simultan[12], [13].Perkembangan arsitektur antar generasi mencakup mekanisme *attention* yang lebih halus, detection head tanpa *anchor* (*anchor-free*) yang diperkenalkan mulai YOLOv10n, serta modul aliran gradien yang lebih baik[15]. Seluruh model dalam penelitian ini diimplementasikan menggunakan framework Ultralytics YOLO.

Kanna et al.[13] dalam tinjauan sistematis menemukan bahwa YOLO efektif untuk berbagai tugas deteksi objek pertanian dengan waktu inferensi rendah dan performa stabil pada berbagai kondisi pencahayaan. Ahmed [12] mengonfirmasi bahwa arsitektur YOLO relatif ringan dan dapat diimplementasikan pada *edge device* seperti *single-board computer* dan perangkat IoT. Sharma et al[19]. dalam studi deteksi gulma multi-spesies mengamati bahwa YOLOv9 mengungguli YOLOv10 yang lebih

baru pada dataset domain-spesifik berukuran sebanding, memperkuat pandangan bahwa kebaruan arsitektur bukan merupakan prediktor performa yang dapat diandalkan ketika data pelatihan terbatas.

3. METODE PENELITIAN

3.1. Lokasi Penelitian dan Pengumpulan Data

Data citra primer dikumpulkan pada tanggal 5 November 2025 dari lahan jagung manis (*Zea mays saccharata*) di Desa Oesao (Kelurahan Babau), Kabupaten Kupang, NTT, Indonesia (koordinat: 10°06'07,0" LS, 123°47'39,9" BT). Pengambilan data dilaksanakan dalam kondisi cuaca cerah sekitar pukul 12.30 WITA (suhu lingkungan 34°C). Citra diambil menggunakan kamera *smartphone* (iPhone 12, sistem kamera ganda 12 MP) dari berbagai sudut, jarak, dan elevasi daun untuk menangkap variasi visual yang memadai. Lahan mencakup sekitar 40 are jagung manis pada fase pertumbuhan vegetatif sekitar dua bulan. Wawancara semi-terstruktur dengan pemilik lahan mengonfirmasi Fall Armyworm sebagai hama dominan pada musim tersebut dan memberikan konteks agronomi.

Dataset pelengkap diperoleh dari repositori publik Roboflow untuk meningkatkan keragaman fenotipik dan lingkungan dari korpus pelatihan. Setelah penggabungan dan deduplikasi, dataset gabungan terdiri dari 2.000 gambar berlabel. Dua kelas deteksi didefinisikan: (i) Hama Fall_armyworm, mewakili spesimen larva; dan (ii) fall_armyworm damage, mewakili pola kerusakan daun khas termasuk perforasi, sobekan tidak beraturan, dan perubahan warna. Anotasi *bounding box* pada data primer dilakukan di Label Studio; anotasi data sekunder diverifikasi dan diharmonisasi di Roboflow. Anotasi diekspor dalam format YOLO TXT (indeks kelas ternormalisasi, x-center, y-center, lebar, tinggi).

3.2. Preprocessing dan Augmentasi

Seluruh gambar diproses melalui platform Roboflow. Citra data primer yang semula tersimpan dalam format HEIC dikonversi terlebih dahulu ke format JPEG sebelum anotasi. Langkah-langkah preprocessing meliputi: (1) normalisasi orientasi otomatis berdasarkan metadata EXIF; (2) pengubahan ukuran ke 640 × 640 piksel menggunakan interpolasi stretch; dan (3) penyesuaian kontras melalui ekualisasi histogram. Augmentasi hanya diterapkan pada subset pelatihan, menghasilkan tiga salinan augmentasi per gambar asli, dan mencakup: *flip horizontal*, rotasi ($\pm 15^\circ$), konversi *grayscale* (diterapkan pada 15% gambar), Gaussian *blur* (hingga 0,5 piksel), dan injeksi noise piksel (hingga 0,61% piksel). Dataset dipartisi menjadi subset pelatihan (90%) dan validasi menggunakan *stratified sampling* untuk mempertahankan distribusi kelas antar subset.

3.3. Arsitektur Model

Lima varian skala nano/tiny dari generasi YOLO terbaru dipilih: YOLOv8n, YOLOv9t, YOLOv10n,

YOLOv11n, dan YOLOv12n. Skala nano/tiny dipilih untuk mencerminkan batasan inferensi yang khas dari penerapan edge-device dalam konteks pertanian skala kecil. Seluruh model diimplementasikan dalam framework Ultralytics YOLO dan dilatih pada Google Colab menggunakan GPU Tesla T4 (16 GB VRAM). Hyperparameter pelatihan yang diterapkan secara seragam pada kelima model disajikan pada Tabel 1.

Tabel 1. Hyperparameter pelatihan yang diterapkan secara seragam pada kelima model YOLO

Hyperparameter	Nilai
Epoch	100
Batch size	16
Optimizer	AdamW
Learning rate awal	0,0001
Ukuran citra input	640 × 640 piksel
Platform	Google Colab (GPU Tesla T4)
Framework	Ultralytics YOLO (Python 3.12)

3.4. Metrik Evaluasi

Performa model dinilai pada split uji menggunakan empat metrik deteksi objek standar: *Precision* (P), *Recall* (R), *F1-Score*, dan *mean Average Precision* (mAP) pada *threshold* IoU 0,5 (mAP@0,5) dan 0,5–0,95 (mAP@0,5–0,95). Metrik-metrik tersebut didefinisikan sebagai: $P = TP / (TP + FP)$; $R = TP / (TP + FN)$; $F1 = 2PR / (P + R)$; di mana TP, FP, dan FN masing-masing merupakan *true positive*, *false positive*, dan *false negative*. *Average Precision* (AP) per kelas dihitung sebagai luas di bawah kurva *Precision–Recall* (PR); mAP merupakan rata-rata AP antar kelas. *F1-Score* digunakan sebagai kriteria peringkat utama karena secara bersamaan mencakup *precision* dan *recall* dalam kondisi ketidakseimbangan kelas [20]. *Confusion matrix* dan visualisasi *train-batch* juga diperiksa secara kualitatif untuk mengidentifikasi pola kesalahan sistematis yang tidak tertangkap oleh metrik agregat.

4. HASIL DAN PEMBAHASAN

4.1. Performa Model Secara Keseluruhan

Tabel 2 menyajikan hasil evaluasi kuantitatif untuk kelima varian YOLO pada split uji. YOLOv11n mencapai skor tertinggi di semua metrik utama, dengan *Precision* 62,7%, *Recall* 59,5%, *F1-Score* 61,1%, mAP@0,5 58,5%, dan mAP@0,5–0,95 35,9%. YOLOv9t berada di peringkat kedua dengan *Precision* individual tertinggi (63,1%), namun *Recall* yang lebih rendah (56,9%) menghasilkan *F1-Score* (59,8%) dan mAP@0,5 (57,7%) yang lebih rendah, menyoroti risiko pembobotan berlebihan pada *Precision* dalam kondisi ketidakseimbangan kelas. YOLOv10n dan YOLOv12n bersama-sama mencatat mAP@0,5 terendah (54,9%), sementara YOLOv8n menempati posisi menengah.

Tabel 2. Hasil evaluasi kelima model YOLO

Model	Precision (%)	Recall (%)	F1-Score (%)	mAP 0,5 (%)	mAP 0,5 – 0,95 (%)
YOLOv8n	58,0	56,0	56,9	56,7	34,0
YOLOv9t	63,1	56,9	59,8	57,7	34,2
YOLOv10n	59,8	55,1	57,3	54,9	34,4
YOLOv11n	62,7	59,5	61,1	58,5	35,9
YOLOv12n	61,9	55,1	58,3	54,9	33,2

Temuan yang sangat penting adalah bahwa YOLOv12n, arsitektur yang paling baru dirilis dalam pengujian ini tidak mengungguli varian-varian sebelumnya dan justru termasuk model dengan performa terendah. Hasil ini konsisten dengan prinsip yang telah mapan dalam *deep learning* bahwa arsitektur yang lebih ekspresif membutuhkan korpus pelatihan yang lebih besar dan beragam secara proporsional untuk mewujudkan keunggulan kapasitasnya[20]. Dengan 2.000 gambar yang diambil dari satu lokasi geografis dan satu musim tanam, kompleksitas representasional yang tertanam dalam mekanisme *attention* YOLOv12n kemungkinan berkontribusi pada generalisasi yang suboptimal dan peningkatan *false positive* pada kelas kerusakan. Sharma et al. [19] mengamati fenomena serupa dalam studi deteksi gulma multi-spesies, di mana YOLOv9 mengungguli YOLOv10 yang lebih baru pada dataset domain-spesifik berukuran sebanding, memperkuat pandangan bahwa kebaruan arsitektur bukan prediktor performa yang dapat diandalkan ketika data pelatihan terbatas.

4.2. Analisis Kinerja Per Kelas


Disparitas yang konsisten dan bermakna ditemukan antara nilai mAP@0,5 per kelas pada seluruh model (Tabel 3). Kelas larva (Hama Fall_armyworm) mencapai skor deteksi hampir sempurna berkisar antara 0,974 hingga 0,988, sementara kelas kerusakan daun (fall_armyworm damage) hanya mencapai maksimum 0,240 (YOLOv11n), dengan seluruh model tersisa pada angka 0,198 atau di bawahnya. Kesenjangan ini rata-rata melebihi empat kali lipat dan bertahan tanpa memandang generasi model, mengonfirmasi bahwa hal ini mencerminkan tantangan data struktural, bukan keterbatasan spesifik model tertentu.

Tabel 3. Nilai mAP@0,5 per kelas untuk setiap model YOLO

Model	Hama Fall_armyworm (mAP@0,5)	fall_armyworm damage (mAP@0,5)
YOLOv8n	0,974	0,164
YOLOv9t	0,988	0,198
YOLOv10n	0,977	0,164
YOLOv11n	0,977	0,240
YOLOv12n	0,974	0,164

Tiga faktor kausal utama diusulkan untuk menjelaskan disparitas tingkat kelas ini. Pertama, ketidakseimbangan kelas: spesimen larva lebih sering dianotasi dibandingkan instans kerusakan di seluruh dataset, dan visualisasi *train-batch* mengonfirmasi bahwa dua model (YOLOv9t dan YOLOv12n) menerima komposisi batch yang didominasi larva secara tidak proporsional, sehingga membiaskan pembelajaran fitur ke arah kelas mayoritas. Ketidakseimbangan kelas merupakan tantangan yang telah terdokumentasi dengan baik dalam dataset deteksi objek pertanian dan umumnya memerlukan strategi mitigasi yang tepat seperti *focal loss reweighting* atau *synthetic oversampling*[21].

Kedua, variabilitas visual intra-kelas yang tinggi: gejala kerusakan berkisar dari perforasi kecil melingkar hingga area nekrotik besar, sobekan tidak beraturan, dan klorosis, yang secara mendasar menyulitkan pembelajaran representasi fitur yang kompak dan konsisten, berbeda tajam dengan fitur morfologis larva Fall Armyworm yang khas dan distingtif. Shandya et al[18]. membuat pengamatan serupa, mencatat bahwa pola kerusakan Fall Armyworm sangat bergantung konteks dan sangat heterogen secara visual, terutama di bawah variasi pencahayaan dan kerumitan latar belakang. Ketiga, kehilangan konteks akibat augmentasi: augmentasi geometris yang agresif, khususnya rotasi sudut besar yang diterapkan secara seragam pada kedua kelas, secara sistematis mendegradasi anotasi area kerusakan dengan mengganggu konteks spasialnya, sementara morfologi larva tetap dapat dikenali dari berbagai orientasi karena pewarnaan dan pola tubuh tersegmentasinya yang khas.



Gambar 1. Kurva *Precision-Recall* YOLOv11n

Gambar 1 menampilkan kurva *Precision-Recall* (PR) YOLOv11n yang secara visual mengonfirmasi disparitas kinerja antar kelas yang dilaporkan pada Tabel 3. Kelas Hama Fall_armyworm (garis biru) membentuk kurva yang hampir persegi panjang sempurna dengan $AP = 0,977$, di mana *precision* bertahan mendekati 1,0 hingga *recall* mencapai sekitar 0,95 sebelum akhirnya turun tajam. Pola ini mengindikasikan bahwa model mampu mendeteksi

hampir seluruh spesimen larva dalam citra uji dengan tingkat *false positive* yang sangat rendah. Sebaliknya, kelas fall_armyworm damage (garis oranye) menunjukkan penurunan *precision* yang sangat cepat sejak *recall* awal, dengan AP hanya 0,240. Area di bawah kurva yang sempit ini secara langsung mencerminkan besarnya jumlah *false negative* pada kelas kerusakan.

4.3. Analisis Confusion Matrix dan Kesalahan Kualitatif

Tabel 4 merangkum distribusi *True Positive* (TP) dan *False Negative* (FN) untuk dua kelas utama dari setiap model. Analisis *confusion matrix* memperkuat temuan kuantitatif tingkat kelas. YOLOv11n mencatat jumlah *true positive* (TP) tertinggi untuk kelas kerusakan (61 objek) dan jumlah *false negative* (FN) terendah untuk kelas larva (3 objek) di antara kelima model, menunjukkan keseimbangan per kelas yang terbaik.

Sebaliknya, YOLOv9t, meskipun memiliki *precision* keseluruhan tertinggi (63,1%), hanya mencatat 15 TP untuk kelas kerusakan dan 423 FN, performa deteksi kerusakan terburuk di antara semua model. Ketidaksesuaian ini menegaskan bahwa *precision* saja merupakan statistik ringkasan yang menyesatkan ketika ketidakseimbangan kelas parah, dan memvalidasi pilihan F1-Score sebagai kriteria peringkat utama.

Tabel 4. Rangkuman *Confusion Matrix* per Model

Model	TP Larva	FN Larva	TP Damage	FN Damage	FP Damage
YOLOv8n	112	7	46	363	32
YOLOv9t	116	9	15	423	2
YOLOv10n	100	7	25	430	15
YOLOv11n	102	3	61	394	21
YOLOv12n	114	13	45	394	32

Analisis *train-batch* kualitatif lebih lanjut mengungkapkan bahwa YOLOv9t dan YOLOv12n berbagi komposisi batch yang pada dasarnya sama, namun menghasilkan profil kesalahan yang secara kualitatif berbeda: YOLOv9t bersifat konservatif (hanya 2 *false positive* pada kelas kerusakan) sementara YOLOv12n terlalu sensitif (32 *false positive*), dengan kesalahan deteksi yang terkonsentrasi pada tekstur latar belakang yang menyerupai kerusakan daun. Divergensi perilaku ini di bawah data pelatihan yang identik mengonfirmasi bahwa perbedaan arsitektur, khususnya kapasitas dan kalibrasi modul attention, mendorong bias deteksi secara independen dari distribusi data. Pola kesalahan ini dapat diamati secara langsung pada contoh hasil deteksi lapangan model terbaik: Gambar 2 menampilkan output inferensi YOLOv11n pada citra uji dari Desa Oesao, memperlihatkan kemampuan model dalam melokalisasi kedua kelas secara simultan melalui *bounding box* pada kondisi lapangan nyata.



Gambar 2. Contoh output deteksi YOLOv11n

Gambar 2 menyajikan *batch* validasi YOLOv11n yang terdiri dari 16 citra representatif beserta hasil prediksi *bounding box*. Kotak biru tua menandai kelas Hama Fall_armyworm (larva), sedangkan kotak biru muda (cyan) menandai kelas fall_armyworm damage (pola kerusakan daun). Secara keseluruhan, model berhasil melokalisasi larva dengan *confidence score* yang konsisten tinggi, mayoritas berada pada rentang 0,8–0,9, pada berbagai kondisi visual: larva tunggal berukuran besar (baris 2 kolom 1 dan 4), beberapa larva berdekatan dalam satu *frame* (baris 2 kolom 2–3), serta larva pada latar belakang bervariasi termasuk tanah, batang jagung, dan tongkol. Kemampuan deteksi multi-objek dalam satu citra juga tampak pada beberapa *frame*, di mana model berhasil memberikan *bounding box* terpisah pada setiap individu larva yang hadir secara bersamaan.

Sebaliknya, deteksi kelas fall_armyworm damage memperlihatkan karakteristik yang berbeda. Kotak cyan muncul lebih jarang dan umumnya disertai *confidence score* yang lebih rendah, berkisar antara 0,3–0,6, mencerminkan ketidakpastian model yang lebih tinggi terhadap pola kerusakan daun. Hal ini konsisten dengan nilai AP = 0,240 yang dilaporkan pada Tabel 3, serta tingginya jumlah *false negative* pada Tabel 4. Variasi visual kerusakan yang tinggi, mulai dari perforasi kecil tidak beraturan hingga sobekan lebar pada lamina daun, sebagaimana terlihat pada baris 3 kolom 2, menjadi tantangan utama yang menyebabkan model kesulitan membentuk representasi fitur yang konsisten untuk kelas ini.

5. KESIMPULAN DAN SARAN

Penelitian ini mengevaluasi lima varian YOLO berbobot ringan (YOLOv8n, YOLOv9t, YOLOv10n, YOLOv11n, dan YOLOv12n) untuk deteksi *Fall Armyworm* dual-kelas pada citra jagung yang dikumpulkan dalam kondisi lapangan nyata di Nusa

Tenggara Timur, Indonesia, dengan YOLOv11n terbukti sebagai model terbaik (F1-Score 61,1%; mAP@0,5 58,5%) berkat keseimbangan per kelas yang paling konsisten. Kebaruan arsitektur tidak menjamin performa superior pada dataset berukuran kecil: YOLOv12n justru termasuk model dengan performa terendah bersama YOLOv10n (mAP@0,5: 54,9%), mengonfirmasi bahwa kapasitas representasional harus disesuaikan dengan skala dan keragaman data. Kesenjangan performa empat kali lipat antara kelas larva (mAP@0,5: 0,974–0,988) dan kelas kerusakan daun (mAP@0,5: 0,164–0,240) yang bertahan di seluruh model disebabkan oleh ketidakseimbangan kelas, variabilitas visual intra-kelas yang tinggi, dan kehilangan konteks anotasi akibat augmentasi geometris.

Penelitian mendatang disarankan untuk memperluas dataset ke beberapa varietas jagung dan lokasi geografis dalam NTT, menerapkan strategi *focal loss reweighting* atau *synthetic oversampling* untuk mengatasi ketidakseimbangan kelas, dan menginvestigasi ekstensi *instance segmentation* serta penerapan *edge deployment* pada perangkat berbiaya rendah untuk mendukung kelayakan praktis bagi petani kecil di NTT.

DAFTAR PUSTAKA

- [1] Y. Achadri, E. yulianes Hosang, P. R. Matitaputty, and C. J. B. Sendow, "Potensi Limbah Jagung Hibrida (*Zea mays* L) sebagai Pakan Ternak di Daerah Dataran Kering Provinsi Nusa Tenggara Timur," *Jurnal Ilmu Nutrisi dan Teknologi Pakan*, vol. 19, no. 2, pp. 42–48, Aug. 2021, doi: 10.29244/jintp.19.2.42-48.
- [2] H. Naisali, J. E. Witoyo, P. A. R. Utoro, and N. D. Permatasari, "Kajian Pustaka Karakteristik Fisiko-Kimia Jagung dari Nusa Tenggara Timur, dan Produk Turunan Tradisionalnya," *AGRICA*, vol. 16, no. 2, pp. 151–163, Aug. 2023, doi: 10.37478/agr.v16i2.3006.
- [3] S. Herlinda, R. Suharjo, M. Elbi Sinaga, F. Fawwazi, and S. Suwandi, "First report of occurrence of corn and rice strains of fall armyworm, *Spodoptera frugiperda* in South Sumatra, Indonesia and its damage in maize," *Journal of the Saudi Society of Agricultural Sciences*, vol. 21, no. 6, pp. 412–419, Sep. 2022, doi: 10.1016/j.jssas.2021.11.003.
- [4] Y. M. S. W. Puu, I. D. Daud, A. Nassrudin, and Melina, "Fall Armyworm *Spodoptera frugiperda* J.E. Smith (Lepidoptera: Noctuidae) in East Nusa Tenggara Province of Indonesia: Genetic Characterization and Strain Detection," *Caraka Tani: Journal of Sustainable Agriculture*, vol. 39, no. 2, pp. 439–450, Oct. 2024, doi: 10.20961/carakatani.v39i2.91748.
- [5] F. and A. O. of the U. N. FAO, "Global Action for Fall Armyworm Control: Action Framework 2020–2022," Rome, Italy, 2020. doi: <https://doi.org/10.4060/ca9252en>.

- [6] K. T. Kareem, F. B. Anjorin, O. O. Odeyemi, and O. A. Akinbode, "Fall armyworm (*Spodoptera frugiperda*) (J. E. Smith) (Lepidoptera: Noctuidae) infestation: maize yield depression and physiological basis of tolerance," 2022, *Polska Akademia Nauk*. doi: 10.24425/jppr.2022.140294.
- [7] R. Setiawan and N. Sari, "Efek Penggunaan Pestisida Berlebih terhadap Lingkungan dan Kesehatan Petani," *Jurnal Agroekoteknologi*, vol. 9, no. 2, pp. 102–110, 2021.
- [8] N. : Mamat, N. I. A. Zawawi, N. M. Zawawi, M. Z. M. Zainuddin, and N. A. M. Salleh, "Advanced Technology in Agriculture Industry by Implementing Image Annotation Technique and Deep Learning Approach: A Review," *Agriculture*, vol. 12, no. 7, 2022.
- [9] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions," *SN Comput. Sci.*, vol. 2, 2021.
- [10] M. O. Ojo and A. Zahid, "Deep Learning in Controlled Environment Agriculture: A Review of Recent Advancements, Challenges and Prospects," *Sensors*, vol. 22, no. 20, 2022.
- [11] J. Liu and X. Wang, "Plant diseases and pests detection based on deep learning: a review," *Plant Methods*, vol. 17, 2021.
- [12] H. Ateeq Ahmed, "Yolo-Based Fast and Accurate Object Detection for Real-Time Applications.," *International Journal of Intelligent Systems and Applications in Engineering*, vol. 12, no. 23s, pp. 2375–2381, Oct. 2024, [Online]. Available: <https://ijisae.org/index.php/IJISAE/article/view/7344>
- [13] K. Kanna S, K. Ramalingam, Pazhanivelan, Jagadeeswaran, and Prabu, "YOLO deep learning algorithm for object detection in agriculture: a review," *Journal of agricultural engineering*, vol. 55, no. 4, 2024, doi: 10.4081/jae.2024.1641.
- [14] D. P. Sari, "Pengembangan Aplikasi Deteksi Penyakit Tanaman Pisang Menggunakan CNN Berbasis Android," *Jurnal Agroinformatika*, vol. 8, no. 2, pp. 112–118, 2022.
- [15] G. Jocher, A. Chaurasia, and J. Qiu, "Ultralytics YOLO," 2023. [Online]. Available: <https://github.com/ultralytics/ultralytics>
- [16] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Comput. Electron. Agric.*, vol. 147, pp. 70–90, 2018.
- [17] R. Hidayat, D. Sulistyono, and R. Yusnita, "Klasifikasi Penyakit Daun Jagung Menggunakan Convolutional Neural Network (CNN)," *Jurnal Teknologi dan Komputer*, vol. 15, no. 1, pp. 23–30, 2023.
- [18] P. Sandhya, B. Venkataramana, T. P. Kumar, and R. Sujatha, "Thermal and RGB image dataset for detection and management of Fall Army Worm (FAW) infestation in maize," *Frontiers in Agronomy*, vol. Volume 7-2025, 2025, doi: 10.3389/fagro.2025.1629681.
- [19] A. Sharma, V. Kumar, and L. Longchamps, "Comparative performance of YOLOv8, YOLOv9, YOLOv10, YOLOv11 and Faster R-CNN models for detection of multiple weed species," *Smart Agricultural Technology*, vol. 9, p. 100648, 2024, doi: <https://doi.org/10.1016/j.atech.2024.100648>.
- [20] B. L. Badger, "Why Deep Learning Generalizes," *ArXiv*, vol. abs/2211.09639, 2022, [Online]. Available: <https://api.semanticscholar.org/CorpusID:253581799>
- [21] T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár, "Focal Loss for Dense Object Detection," in *2017 IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 2999–3007. doi: 10.1109/ICCV.2017.324.