Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

Implementasi YOLOv11-Segmentation dan Metode HSV untuk Estimasi Tingkat Kerusakan Daun Jagung Berbasis Pengolahan Citra

Muhammad Fadil Assalim[1*]✉, Bala Wardana Putra[1]✉, Vira Septiani[1]✉, Rachmat Adi Purnama[1]✉, Sujiliani Heristian[2]✉, Veti Apriana[3]✉
[1]Informatika, Universitas Bina Sarana Informatika, Indonesia
[2]Teknik Komputer, Universitas Bina Sarana Informatika, Indonesia
[3]Teknik Industri, Universitas Bina Sarana Informatika, Indonesia

Abstrak

Serangan penyakit seperti hawar, karat, dan bercak daun abu-abu memengaruhi produktivitas jagung di Indonesia. Namun, penilaian manual memiliki keterbatasan karena bersifat subjektif. Penelitian ini bertujuan mengembangkan sistem estimasi tingkat kerusakan daun jagung berbasis piksel dengan mengintegrasikan YOLOv11-Segmentation dan pengolahan citra HSV. Dataset pelatihan terdiri atas 2.500 citra dari Kaggle, meliputi 750 citra daun sehat, 1.000 citra daun rusak, dan 750 citra non-daun. Anotasi segmentasi dibuat secara otomatis menggunakan OpenCV melalui HSV thresholding dan deteksi kontur. Model YOLOv11n-Seg dilatih selama 60 epoch pada resolusi 640 × 640 piksel. Kebaruan pendekatan terletak pada operasi bitwise AND antara mask daun hasil YOLOv11-Segmentation dan mask kandidat kerusakan hasil HSV, sehingga penghitungan piksel kandidat kerusakan dibatasi pada area daun. Rentang HSV daun ditetapkan pada [30,40,40]–[85,255,255], sedangkan rentang kandidat kerusakan pada [10,40,40]–[35,255,255]. Evaluasi segmentasi pada 375 citra testing menghasilkan mAP@50 sebesar 90,90% untuk bounding box dan 87,80% untuk mask. Pada evaluasi klasifikasi tingkat kerusakan terhadap 256 citra daun jagung yang telah diberi label aktual melalui pemeriksaan visual peneliti, sistem YOLO+HSV memperoleh akurasi 79,69% dan macro F1-score 82,93%. Sebagai pembanding, HSV murni memperoleh akurasi 86,33% dan macro F1-score 83,76%. Hasil menunjukkan bahwa integrasi YOLO+HSV membatasi area analisis, tetapi belum meningkatkan seluruh metrik klasifikasi pada data uji ini. Estimasi area berbasis warna masih memerlukan validasi pixel-level independen.

Kata Kunci: Daun Jagung; YOLOv11-Segmentation; HSV Thresholding; Segmentasi Citra; Tingkat Kerusakan.

Abstract

Diseases such as blight, rust, and gray leaf spot affect corn productivity in Indonesia. However, manual assessment has limitations due to its subjective nature. This study aims to develop a pixel-based corn leaf damage level estimation system by integrating YOLOv11-Segmentation and HSV image processing. The training dataset consists of 2,500 Kaggle images, comprising 750 healthy leaf images, 1,000 damaged leaf images, and 750 non-leaf images. Segmentation annotations were generated automatically using OpenCV through HSV thresholding and contour detection. The YOLOv11n-Seg model was trained for 60 epochs at a resolution of 640 × 640 pixels. The novelty of this approach lies in applying a bitwise AND operation between the leaf mask generated by YOLOv11-Segmentation and the candidate damage mask from HSV thresholding, restricting candidate damage pixels to the leaf area. The leaf HSV range was set at [30, 40, 40]–[85, 255, 255], while the candidate damage range was [10, 40, 40]–[35, 255, 255]. Segmentation evaluation on 375 testing images achieved an mAP@50 of 90.90% for bounding boxes and 87.80% for masks. In damage level classification on 256 corn leaf images labeled by researchers' visual inspection, YOLO+HSV achieved an accuracy of 79.69% and a macro F1-score of 82.93%, compared with 86.33% and 83.76% for pure HSV. The integration restricts the analysis area but has not improved all classification metrics on this test set. Color-based area estimation still requires independent pixel-level validation.

Keywords: *Maize; YOLOv11; HSV Thresholding; Image Segmentation; Damage Severity.*

***Corresponding Author:**
Muhammad Fadil Assalim, Universitas Bina Sarana Informatika, Indonesia
Email: muhammadfadilassalim@gmail.com

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

1. PENDAHULUAN

Di Indonesia, jagung (*Zea mays* L.) merupakan komoditas pangan strategis yang menopang ketahanan pangan, sektor pakan ternak, dan bahan baku industri. Namun, produktivitasnya kerap terhambat penyakit pada daun, seperti hawar daun (*Northern Leaf Blight*), karat daun (*Common Rust*), dan bercak daun abu-abu (*Gray Leaf Spot*), yang mengubah warna, bentuk, dan struktur jaringan daun sehingga dapat mengganggu fotosintesis dan pertumbuhan tanaman. Albana dan Resti melaporkan bahwa kejadian penyakit karat daun jagung di Kecamatan Kuranji mencapai 100% dengan tingkat keparahan 32,52% (kategori sedang)[1]. Pada skala global, karat jagung selatan (*Southern Corn Rust*) bahkan dilaporkan dapat menurunkan produksi jagung hingga 50% atau bahkan 100% pada tahun epidemi, sehingga diagnosis tingkat keparahan penyakit di lapangan menjadi kebutuhan penting[2]. Kondisi ini menegaskan pentingnya penilaian kerusakan daun yang objektif, konsisten, dan terukur.

Kendala utama pengukuran tingkat keparahan adalah ketergantungan pada inspeksi visual manual, yang rentan menimbulkan perbedaan interpretasi antarpenilai, terutama dalam menentukan luas daun yang rusak, dan belum tentu menggambarkan persentase kerusakan secara kuantitatif; kuantifikasi manual semacam ini juga dinilai padat karya, memakan waktu, dan rawan galat karena belum memiliki pedoman diagnosis yang terstandar[3]. Setyawan et al. mengklasifikasikan penyakit daun jagung dengan ruang warna *Hue, Saturation, Value* (HSV), fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM), dan algoritma *K-Nearest Neighbors* (K-NN); akurasi tertinggi fitur tekstur adalah 84%, sedangkan fitur warna HSV hanya 64%[4]. Temuan ini menunjukkan bahwa informasi warna saja terbatas, sehingga dibutuhkan skema komputasi yang juga mampu memisahkan daun dari latar belakang dan menghitung luas kerusakan berbasis piksel.

Perkembangan kecerdasan buatan (*artificial intelligence*) dan pengolahan citra digital (*digital image processing*) telah melahirkan berbagai pendekatan untuk mendeteksi dan mengklasifikasikan penyakit tanaman secara otomatis. Wirabowo dan Susilawati menerapkan *Convolutional Neural Network* (CNN) pada 2.960 citra tiga kategori penyakit dan memperoleh akurasi validasi 90,03%[5]. Kusuma et al. membandingkan *Support Vector Machine* (SVM), K-NN, dan *Multilayer Perceptron* (MLP) dengan VGG-16 sebagai ekstraktor fitur; MLP terbaik dengan akurasi, presisi, dan *recall* masing-masing 97,4%[6]. Joseph et al. membangun dataset penyakit tanaman pangan dan menguji delapan model *deep learning*, dengan Xception mencapai akurasi 95,80% pada daun jagung[7]. Saeed et al. memperoleh akurasi 98,51% pada citra daun jagung melalui ResNet152[8], sedangkan Pangestu et al. melaporkan akurasi 80%, presisi 80%, *recall* 81%, dan *F1-score* 79% dengan CNN[9]. Meskipun menjanjikan, sebagian besar pendekatan tersebut masih berorientasi pada pengenalan atau klasifikasi jenis penyakit, tetapi belum menghasilkan informasi spasial mengenai persentase area kerusakan pada permukaan daun jagung.

Dengan demikian, masih terdapat kesenjangan penelitian (research gap) pada perhitungan tingkat keparahan berdasarkan persentase luas daun yang terdampak. Lakehal et al. mengestimasi keparahan penyakit daun gandum dengan CNN ensemble dan SVM, tetapi fokusnya klasifikasi tingkat keparahan karat kuning pada gandum, bukan pengukuran luas kerusakan pada daun jagung[10]. Putra dan Fachrie membandingkan segmentasi klasik, U-Net, dan YOLOv11-seg untuk mengestimasi luas daun pepaya, dengan IoU YOLOv11-seg sebesar 0,904[11]. Pendekatan pengolahan citra menggunakan OpenCV dan ruang warna HSV telah diterapkan untuk mengidentifikasi area lesi penyakit daun padi. Luas lesi dihitung berdasarkan jumlah piksel yang terindikasi sebagai penyakit dibandingkan dengan total piksel daun, kemudian digunakan untuk memperkirakan persentase keparahan berdasarkan skala penilaian IRRI. Namun, penelitian tersebut menggunakan EfficientNetV2-S dan ResNet50 untuk klasifikasi jenis penyakit, bukan YOLOv11-Segmentation untuk memisahkan objek daun dari latar belakang[12]. Pada cakupan referensi yang ditinjau, integrasi YOLOv11-Segmentation dan HSV Thresholding untuk mengestimasi persentase area rusak pada daun jagung belum banyak dibahas.

Berdasarkan kesenjangan tersebut, penelitian ini mengusulkan sistem penilaian tingkat keparahan penyakit daun jagung yang mengintegrasikan YOLOv11-Segmentation dan HSV *Thresholding*. YOLOv11-Segmentation memisahkan daun dari latar belakang sehingga diperoleh *mask* daun sebagai dasar pengukuran; selanjutnya HSV *Thresholding* dengan batas bawah (10, 40, 40) dan batas atas (35,

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

255, 255) mengidentifikasi piksel berwarna khas kerusakan. Rasio piksel rusak terhadap total piksel daun menghasilkan persentase keparahan yang dikelompokkan menjadi sehat (<1%), ada kerusakan (1%–30%), dan rusak parah (>30%). Kebaruan penelitian ini terletak pada penggabungan kedua *mask* tersebut untuk menghitung persentase area terindikasi rusak berbasis piksel.

Tujuan penelitian ini adalah mengembangkan dan mengimplementasikan sistem penilaian tingkat keparahan penyakit daun jagung secara otomatis, dengan menilai kemampuan YOLOv11-Segmentation dalam segmentasi daun, penerapan HSV *Thresholding* dalam mendeteksi warna kerusakan, serta pengukuran persentase kerusakan berdasarkan perbandingan piksel. Kontribusi yang diharapkan berupa pendekatan pengukuran yang lebih objektif dan terukur untuk mendukung pemantauan tanaman dalam pertanian cerdas (*smart farming*) dan pengambilan keputusan penanganan penyakit. Bagian berikutnya memaparkan metode penelitian, hasil dan pembahasan, serta kesimpulan.

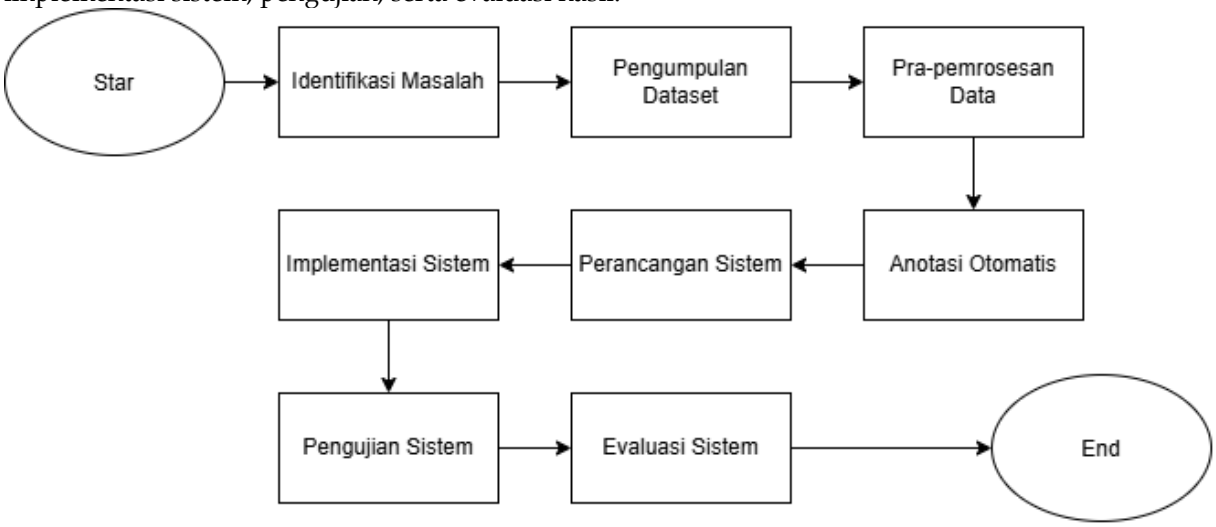
2. METODE PENELITIAN

2.1. Metode Penelitian

Penelitian ini menggunakan pendekatan pengembangan dan evaluasi sistem pengolahan citra. Tahapan penelitian mencakup persiapan dataset, pra-pemrosesan, pembuatan anotasi segmentasi otomatis, pelatihan YOLOv11-Segmentation, integrasi mask dengan HSV, implementasi aplikasi, serta evaluasi segmentasi dan klasifikasi tingkat kerusakan.

2.2. Tahapan Penelitian

Tahapan penelitian disusun secara berurutan sebagaimana ditunjukkan pada Gambar 1, meliputi identifikasi permasalahan, pengumpulan data, pra-pemrosesan, anotasi otomatis, perancangan dan implementasi sistem, pengujian, serta evaluasi hasil.



Gambar 1. Diagram Tahapan Penelitian

Identifikasi Potensi dan Permasalahan

Permasalahan utama adalah penilaian kerusakan daun jagung yang masih banyak dilakukan secara visual dan manual sehingga berpotensi menimbulkan perbedaan interpretasi luas area rusak. Hawar daun, karat daun, dan bercak daun abu-abu mengubah warna dan merusak jaringan permukaan daun. Karena itu diperlukan sistem yang secara otomatis menyegmentasi daun, mengidentifikasi area rusak, dan menghitung keparahan berdasarkan luas area terdampak, yang diwujudkan melalui integrasi YOLOv11-Segmentation dan HSV *Thresholding*.

Pengumpulan Kebutuhan Data

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

Dataset citra daun jagung diperoleh dari Kaggle dan terdiri atas daun sehat, daun rusak, dan sampel negatif (gambar non-daun) yang digabung dalam satu folder utama. Rincian dataset ditunjukkan pada Tabel 1.

Tabel 1. Jumlah Dataset

No	Kelompok Citra	Jumlah Citra
1	Daun Sehat	750
2	Daun Rusak	1.000
3	Sampel Negatif	750
	Total	2.500

Total dataset berjumlah 2.500 citra. Daun sehat menjadi contoh kondisi normal, sedangkan daun rusak menjadi contoh gejala penyakit, yaitu hawar daun (*Northern Leaf Blight*) dengan lesi memanjang, karat daun (*Common Rust*) dengan pustula cokelat kemerahan, dan bercak daun abu-abu (*Gray Leaf Spot*) dengan bercak memanjang abu-abu hingga cokelat. Sampel negatif membantu model mengenali gambar tanpa objek daun jagung. Objek daun diperlakukan sebagai satu kelas segmentasi, dan dataset dibagi menjadi 70% data *training* (1.750 citra), 15% data *validation* (375 citra), dan 15% data *testing* (375 citra).

Pada evaluasi segmentasi model, data testing mengikuti pembagian awal sebanyak 375 citra. Untuk evaluasi klasifikasi tingkat kerusakan berbasis aplikasi, citra non-daun dan citra yang bukan daun jagung dikeluarkan setelah pemeriksaan, sehingga diperoleh 256 citra daun jagung: 116 sehat, 61 ada kerusakan, dan 79 rusak parah. Label aktual pada 256 citra ditentukan melalui pemeriksaan visual oleh peneliti. Dua sesi percakapan Gemini yang terpisah digunakan sebagai pembanding identifikasi; apabila terdapat perbedaan, peneliti memeriksa ulang citra dan menetapkan label akhir. Dengan demikian, label tersebut merupakan label referensi berbasis penilaian visual peneliti dengan bantuan pembanding AI, bukan anotasi mask tingkat piksel.

Pra-pemrosesan Data

Pra-pemrosesan (*data preprocessing*) dilakukan dengan OpenCV untuk menyiapkan citra dan memisahkan daun dari latar belakang melalui empat langkah. Pertama, citra berformat JPG, JPEG, dan PNG dibaca dengan cv2.imread(). Kedua, ruang warna dikonversi dari BGR ke HSV dengan cv2.cvtColor(); HSV terdiri atas *Hue* (jenis warna), *Saturation* (kejenuhan), dan *Value* (kecerahan). Ketiga, HSV *Thresholding* dengan cv2.inRange() memakai batas bawah [30, 40, 40] dan batas atas [85, 255, 255] untuk menghasilkan *mask* area daun. Keempat, operasi morfologi *closing* dan *opening* dengan kernel elips 7 × 7 menutup lubang kecil dan menghilangkan gangguan sehingga *mask* lebih baik sebelum anotasi otomatis.

Anotasi Otomatis

Anotasi otomatis memberi label lokasi dan bentuk objek bagi YOLOv11-Segmentation dengan memanfaatkan *mask* HSV melalui OpenCV. Kontur daun dideteksi dengan cv2.findContours(), dan hanya kontur yang luasnya lebih dari 3% luas gambar yang dipertahankan agar gangguan kecil tidak dianggap sebagai daun. Kontur disederhanakan dengan cv2.approxPolyDP() menjadi poligon, koordinatnya dinormalisasi ke rentang 0–1 sesuai format segmentasi YOLO, lalu disimpan dalam berkas TXT dengan indeks kelas 0 (daun). Citra tanpa kontur yang memenuhi kriteria disimpan dengan label kosong sebagai sampel negatif (*negative sample*) agar model lebih jarang keliru mendeteksi objek non-daun.

Anotasi otomatis menimbulkan potensi bias anotasi melingkar (*circular annotation bias*) bagi YOLOv11-Segmentation akibat keterbatasan proses pembuatan label menggunakan OpenCV. Keterbatasan tersebut dipicu oleh HSV Thresholding dan cv2.findContours(), sehingga model hanya mempelajari pola batas objek berdasarkan hasil pelabelan otomatis tersebut alih-alih merujuk pada batas daun sebenarnya yang diverifikasi secara manual oleh ahli. Kesalahan berupa bagian daun yang terlewat atau area latar belakang yang ikut teranotasi akan diteruskan jika proses HSV atau deteksi

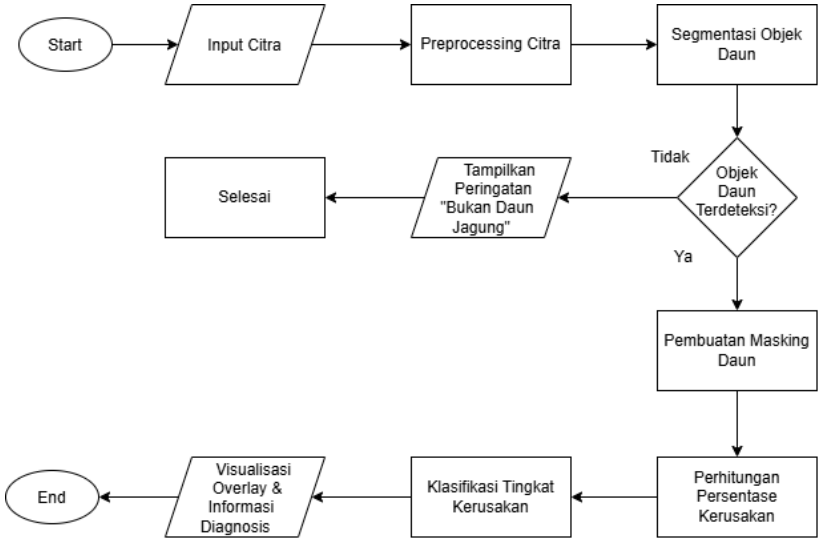
Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

kontur keliru, lalu pola eror tersebut ikut dipelajari oleh model selama pelatihan berlangsung. Evaluasi model terhadap label otomatis akhirnya belum sepenuhnya mencerminkan tingkat akurasi segmentasi riil, melainkan baru merepresentasikan kapasitas model dalam mereproduksi pola anotasi yang tersedia alih-alih menjadi validasi independen terhadap batas anatomis daun. Pengukuran kesesuaian segmentasi secara lebih objektif disarankan untuk penelitian selanjutnya dengan menggunakan anotasi manual yang telah diperiksa oleh ahli sebagai standar pengujian.

Perancangan Sistem

Perancangan sistem menentukan alur kerja penilaian kerusakan daun jagung dengan menggabungkan segmentasi YOLOv11-Segmentation dan pengolahan warna HSV *Thresholding*. Alur sistem ditunjukkan pada Gambar 2 dan terdiri atas sembilan proses berikut.



Gambar 2. Diagram Alur Sistem

Tahap pertama input citra, yaitu pengguna mengunggah gambar daun jagung atau mengambilnya langsung melalui kamera pada aplikasi web. Tahap kedua preprocessing citra, yaitu *resizing* dan konversi ruang warna BGR ke RGB dan HSV dengan OpenCV. Tahap ketiga segmentasi objek daun, yaitu pemisahan daun dari latar belakang (*background noise*) dengan YOLOv11-Segmentation. Tahap keempat validasi objek daun, yaitu pengecekan keberadaan daun pada ambang konfidensi tertentu; bila tidak terdeteksi (sampel negatif), proses dihentikan dan sistem menyatakan gambar bukan daun jagung. Tahap kelima pembuatan mask daun, yaitu pembentukan citra biner area daun dari prediksi YOLOv11. Tahap Keenam deteksi area kerusakan, yaitu identifikasi piksel bergejala (karat, hawar, atau bercak) dengan HSV *Thresholding* yang digabung dengan *mask* daun melalui operasi *bitwise* AND. Tahap ketujuh perhitungan persentase kerusakan, yaitu perbandingan jumlah piksel kerusakan terhadap seluruh piksel daun. Tahap kedelapan klasifikasi tingkat kerusakan, yaitu penentuan kategori sehat, ada kerusakan, atau rusak parah berdasarkan persentase. Tahap kesembilan visualisasi dan hasil diagnosis, yaitu penayangan *overlay* segmentasi dan bercak, persentase, kategori, serta rekomendasi tindakan teknis pertanian.

Implementasi Sistem

Implementasi menerapkan rancangan ke dalam program melalui pelatihan model di Google Colab serta pengembangan aplikasi deteksi dan klasifikasi dengan Python dan FastAPI.

Pelatihan Model YOLOv11-Segmentation

Pelatihan memakai pustaka Ultralytics dengan model YOLOv11n-Seg berbobot awal yolo11n-seg.pt pada dataset beranotasi otomatis (satu kelas daun berindeks 0; gambar non-daun berlabel kosong).

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

Konfigurasi pelatihan adalah 60 epoch, ukuran citra 640 × 640 piksel, batch size 16, dan pembagian data 70%:15%:15%. Model terbaik disimpan sebagai best.pt dan digunakan pada aplikasi untuk segmentasi daun.

Pengembangan Aplikasi dan Segmentasi Daun

Model best.pt diintegrasikan ke aplikasi berbasis Python dan FastAPI; berkas main.py mengatur penerimaan gambar, pemrosesan, prediksi segmentasi, perhitungan persentase kerusakan, dan penampilan hasil dengan dukungan Ultralytics YOLO, OpenCV, dan NumPy. Gambar yang diunggah dibaca dengan OpenCV, diubah menjadi larik NumPy, lalu dikonversi dari BGR ke RGB dan HSV. Segmentasi dijalankan dengan confidence threshold 0,60; jika tidak ada objek atau mask yang dihasilkan, sistem menyatakan gambar bukan daun jagung. Mask disesuaikan dengan ukuran gambar asli melalui cv2.resize() dan, bila lebih dari satu, digabung dengan operasi bitwise OR menjadi satu mask daun yang menjadi dasar penghitungan total piksel daun sekaligus pembatas area deteksi kerusakan.

Deteksi Area Kerusakan dengan HSV Thresholding

Piksel dengan warna cokelat atau kuning tua yang berpotensi berkaitan dengan kerusakan diidentifikasi menggunakan cv2.inRange() pada rentang HSV bawah (10, 40, 40) dan atas (35, 255, 255). Rentang kandidat daun yang digunakan pada tahap anotasi adalah (30, 40, 40) hingga (85, 255, 255). Dengan demikian, terdapat tumpang tindih nilai Hue 30–35. Tumpang tindih ini dipertahankan karena sebagian warna transisi pada daun dan sebagian warna lesi dapat berada pada rentang tersebut; namun, konsekuensinya sebagian piksel daun normal yang berada pada Hue 30–35 berpotensi ikut teridentifikasi sebagai kandidat kerusakan. Operasi bitwise AND dengan mask daun membatasi piksel kandidat kerusakan pada area daun, tetapi tidak menghilangkan seluruh false positive yang berada di dalam daun. Karena itu, hasil HSV ditafsirkan sebagai area yang terindikasi rusak, bukan identifikasi jaringan penyakit yang telah tervalidasi secara biologis.

Kondisi pencahayaan dan variasi warna daun tetap memengaruhi hasil pengukuran, sehingga rentang HSV perlu dievaluasi kembali pada penelitian mendatang dengan data yang mencakup variasi warna daun dan pencahayaan yang lebih luas. Mask hasil penyaringan digabung dengan mask daun melalui operasi bitwise AND sehingga piksel berwarna serupa pada latar belakang tidak ikut dihitung sebagai kerusakan.

Perhitungan Persentase Kerusakan

Luas daun adalah jumlah piksel pada mask daun, sedangkan luas kerusakan adalah jumlah piksel berwarna kerusakan di dalam daun. Persentase kerusakan dihitung dengan persamaan (1).

$$P_{\text{kerusakan}} = \left(\frac{N_{\text{kerusakan}}}{N_{\text{daun}}}\right) \times 100\% \quad (1)$$

dengan $P_{kerusakan}$ adalah persentase tingkat kerusakan daun (%), $N_{kerusakan}$ adalah jumlah piksel area kerusakan (hasil HSV AND *mask* YOLOv11), dan N_{daun} adalah jumlah piksel total area daun (hasil segmentasi YOLOv11). Nilai ini menjadi dasar penentuan kategori kerusakan.

Klasifikasi Tingkat Kerusakan Daun Jagung

Tabel 2. Kriteria Klasifikasi Tingkat Kerusakan Daun Jagung

No	Kategori	Persentase Kerusakan
1	Sehat	< 1%
2	Ada Kerusakan	≥ 1% – ≤ 30%
3	Rusak Parah	> 30%

Sistem mengelompokkan daun menjadi tiga kategori berdasarkan persentase kerusakan (Tabel 2): sehat bila kurang dari 1% (daun relatif normal), ada kerusakan bila 1%–30% (terdapat bercak atau

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

perubahan warna pada sebagian permukaan daun, tetapi belum meluas), dan rusak parah bila lebih dari 30% (kerusakan meluas pada bagian besar permukaan daun).

Visualisasi Hasil dan Rekomendasi

Sistem menampilkan tiga visualisasi, yaitu overlay segmentasi dan kerusakan (daun berlapis hijau, area rusak merah), mask daun hasil YOLOv11-Segmentation, dan mask kerusakan hasil HSV Thresholding, disertai informasi diagnosis berupa kategori kondisi, persentase kerusakan, jumlah piksel daun dan kerusakan, serta deskripsi dan rekomendasi tindakan sesuai kategori.

Pengujian Sistem

Pengujian dilakukan dengan memasukkan citra daun sehat, daun rusak akibat penyakit, dan sampel negatif non-daun ke aplikasi. Aspek yang diuji meliputi deteksi objek daun, segmentasi, deteksi kerusakan, perhitungan persentase, klasifikasi, dan visualisasi. Kinerja segmentasi dievaluasi dengan Precision, Recall, dan mean Average Precision (mAP50) seperti pada (2).

$$\text{Precision} = \frac{TP}{TP + FP}, \quad \text{Recall} = \frac{TP}{TP + FN} \tag{2}$$

Dengan TP adalah deteksi benar (true positive), FP adalah deteksi salah (false positive), dan FN adalah objek daun yang tidak terdeteksi (false negative); Precision menyatakan ketepatan prediksi dan Recall menyatakan kemampuan model menemukan seluruh objek daun. Klasifikasi tingkat kerusakan dievaluasi dengan confusion matrix 3×3, accuracy, serta macro Precision, Recall, dan F1-score, sedangkan efisiensi komputasi diukur melalui latency dan FPS.

Evaluasi dan Perbaikan

Evaluasi berdasarkan hasil pengujian menilai kesesuaian segmentasi daun, ketepatan deteksi area kerusakan, hasil perhitungan persentase, dan kategori yang dihasilkan. Bila ditemukan ketidaksesuaian, perbaikan dapat dilakukan pada preprocessing citra, konfigurasi model segmentasi, rentang nilai HSV, maupun mekanisme perhitungan dan klasifikasi agar sistem lebih konsisten.

2.3. Metode Segmentasi YOLOv11-Segmentation

YOLOv11-Segmentation adalah algoritma *deep learning* untuk deteksi dan segmentasi objek pada citra digital. Menurut He et al., arsitekturnya (*Backbone*, *Neck*, dan *Head*) mengoptimalkan ekstraksi fitur dan penggabungan informasi multi-skala sehingga meningkatkan presisi *instance segmentation* sekaligus kecepatan pemrosesan[13]. Sapkota dan Karkee juga menemukan bahwa varian YOLOv11-Seg efisien dalam parameter dan tangguh dalam mengisolasi objek target pada lingkungan visual yang kompleks[14]. Penelitian ini memakai YOLOv11n-Seg dengan satu kelas objek, yaitu daun jagung, sehingga model hanya menghasilkan *mask* area daun untuk mengukur luas daun dan membatasi wilayah deteksi kerusakan, bukan membedakan jenis penyakit atau tingkat keparahan.

2.4. Metode HSV Thresholding

HSV (*Hue, Saturation, Value*) merepresentasikan warna melalui jenis warna, kejenuhan, dan kecerahan. Menurut Hamuda et al., HSV efektif mengisolasi objek target dari latar belakang kompleks (seperti tanah atau gulma) melalui *thresholding* pada tiap saluran dan tahan terhadap variasi pencahayaan di area pertanian[15]. He et al. menambahkan bahwa *Hue* memberi informasi diskriminatif warna yang stabil, sedangkan *Saturation* dan *Value* menyaring gangguan latar belakang di lingkungan luar ruangan[16]. Pada penelitian ini piksel berwarna bercak dipisahkan dengan batas bawah (10, 40, 40) dan batas atas (35, 255, 255), lalu dibatasi oleh *mask* YOLOv11-Segmentation sehingga HSV menentukan jumlah piksel rusak dan YOLOv11-Segmentation menentukan total area daun sebagai pembanding, sebagaimana pada (3).

$$M_{\text{final}}(x, y) = M_{\text{YOLO}}(x, y) \wedge M_{\text{HSV}}(x, y) \tag{3}$$

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

dengan Mfinal(x,y) adalah piksel mask akhir area kerusakan daun, MYOLO(x,y) adalah piksel biner hasil segmentasi daun YOLOv11, dan MHSV(x,y) adalah piksel biner hasil penyaringan warna bercak HSV.

2.5. Hasil yang Diharapkan

Sistem diharapkan mampu memisahkan daun dari latar belakang, mengidentifikasi area berwarna kerusakan, menghitung persentase luas kerusakan berbasis piksel, dan mengelompokkan kondisi daun menjadi sehat, ada kerusakan, atau rusak parah, lengkap dengan visualisasi, diagnosis, dan rekomendasi tindakan, sehingga penilaian keparahan menjadi lebih objektif, terukur, dan efisien.

3. HASIL DAN PEMBAHASAN

Bagian ini membahas hasil persiapan dataset, pelatihan, evaluasi pada data validation dan testing, penerapan HSV untuk menghitung persentase area rusak, serta keterbatasan sistem.

3.1. Hasil Persiapan Dataset

Dataset 2.500 citra Kaggle (750 daun sehat, 1.000 daun rusak, dan 750 non-daun) diproses melalui pra-pemrosesan dan anotasi otomatis OpenCV (HSV, thresholding, dan deteksi kontur) untuk menghasilkan label segmentasi satu kelas, yaitu daun jagung; citra non-daun menjadi sampel negatif. Pembagian data ditunjukkan pada Tabel 3.

Tabel 3. Pembagian Dataset

No	Jenis Data	Jumlah Data	Persentase
1	Training	1.750	**70%**
2	Validation	375	**15%**
3	Testing	375	**15%**
	Total	2.500	**100%**

Sebagian besar citra digunakan untuk pelatihan. Data validation memantau performa selama pengembangan, sedangkan data testing memberikan evaluasi pada data yang terpisah dari pelatihan dan validasi.

3.2. Hasil Pelatihan dan Evaluasi pada Data Validation

Model YOLOv11n-Seg (bobot awal yolo11n-seg.pt) dilatih 60 epoch dengan citra 640 × 640 piksel dan batch size 16 untuk satu kelas objek, yaitu daun jagung, sehingga pelatihan berfokus pada deteksi dan segmentasi daun, bukan klasifikasi jenis penyakit. Model terbaik disimpan sebagai best.pt. Hasil evaluasi pada data validation ditunjukkan pada Tabel 4.

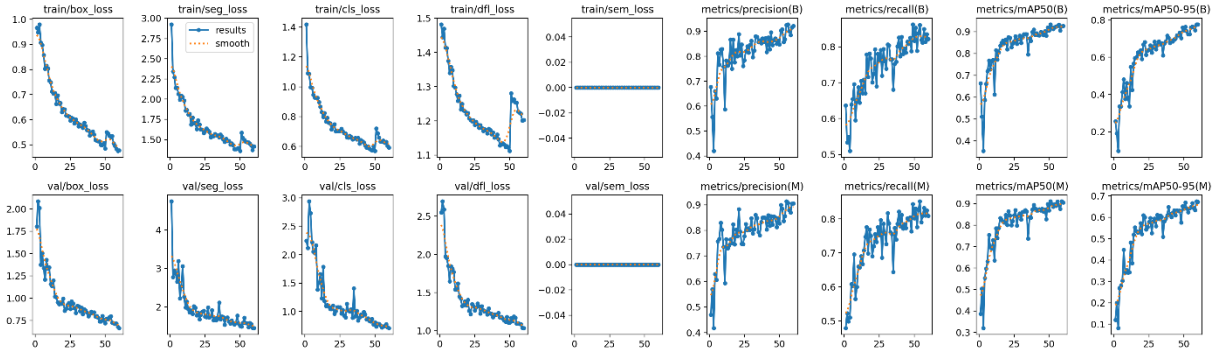
Tabel 4. Hasil Evaluasi Model pada Data Validation

Metrik	Bounding Box	Segmentation Mask
Precision	92,16%	90,58%
Recall	82,22%	80,93%
mAP@50	92,62%	90,61%
mAP@50-95	77,75%	67,14%

Model memperoleh mAP@50 sebesar 92,62% pada bounding box dan 90,61% pada segmentation mask, dengan Precision 92,16% dan 90,58% serta Recall 82,22% dan 80,93%. Nilai segmentation mask yang lebih rendah menunjukkan bahwa kesesuaian area segmentasi masih perlu diperhatikan, karena mask menjadi dasar perhitungan luas total daun.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851



Gambar 3. Grafik Hasil Pelatihan dan Validasi YOLOv11-Segmentation

Gambar 3 menampilkan perubahan nilai loss dan metrik evaluasi pada setiap epoch selama pelatihan dan validasi.

3.3. Hasil Pengujian Model pada Data Testing

Evaluasi klasifikasi tingkat kerusakan dilakukan secara terpisah pada 256 citra daun jagung yang telah disaring dan diberi label aktual secara visual. Sementara itu, evaluasi segmentasi model dilakukan pada 375 citra testing (408 instances dan 82 backgrounds, tanpa berkas label corrupt) dengan hasil pada Tabel 5.

Tabel 5. Hasil Evaluasi Model pada Data Testing

Metrik	Bounding Box	Segmentation Mask
Precision	90,30%	86,40%
Recall	78,20%	76,20%
mAP@50	90,90%	87,80%
mAP@50-95	76,80%	65,60%

Pada data testing, bounding box memperoleh Precision 90,30%, Recall 78,20%, mAP@50 90,90%, dan mAP@50–95 76,80%; segmentation mask memperoleh Precision 86,40%, Recall 76,20%, mAP@50 87,80%, dan mAP@50–95 65,60%. Penurunan Recall mask menunjukkan bahwa sebagian objek daun pada label pengujian tidak berhasil ditemukan, sedangkan penurunan mAP@50–95 dibandingkan mAP@50 menunjukkan bahwa ketepatan tumpang tindih mask menurun pada ambang IoU yang lebih ketat. Perbedaan ini dapat berkaitan dengan batas mask yang kurang presisi, variasi bentuk daun, pencahayaan, oklusi, dan keterbatasan anotasi otomatis OpenCV. Karena anotasi acuan juga dibentuk otomatis menggunakan HSV dan kontur, metrik ini mengukur kesesuaian terhadap anotasi tersebut dan belum menjadi validasi independen terhadap batas anatomis daun.

Pengujian inferensi dilakukan menggunakan CPU pada lingkungan Google Colab, bukan GPU. Lingkungan yang tercatat menggunakan arsitektur x86_64 dengan 2 core CPU dan RAM sekitar 12,67 GB; model best.pt berukuran 5,899 MB. Waktu rata-rata inferensi YOLO+HSV yang diperoleh pada pengukuran CPU adalah 251,187 ms dengan median 250,297 ms dan kecepatan sekitar 3,981 FPS. Angka ini menggambarkan kinerja pada lingkungan pengujian tersebut dan bukan klaim kinerja perangkat keras lain.

3.4. Hasil Implementasi Aplikasi

Setelah daun disegmentasi, HSV Thresholding dengan batas bawah (10, 40, 40) dan batas atas (35, 255, 255) diterapkan hanya di dalam mask daun, sehingga piksel dihitung sebagai kerusakan hanya bila berada pada objek daun. Persentase area rusak dihitung menggunakan (1) pada bagian metode.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851



Gambar 4. Hasil Implementasi Aplikasi

Gambar 4 menampilkan antarmuka diagnosis tingkat kerusakan daun dengan pendekatan hibrida kecerdasan buatan dan pengolahan citra digital, yang menggabungkan model segmentasi instan YOLOv11 dan ekstraksi warna HSV untuk mengukur persentase kerusakan secara kuantitatif. Luas total daun hasil segmentasi YOLOv11 adalah 102.724 px (panel Mask Daun), sedangkan luas kerusakan hasil thresholding HSV adalah 42.556 px (panel Mask Kerusakan). Tingkat keparahan dihitung menurut (1) dengan nilai berikut.

$$P_{kerusakan} = \frac{42.556}{102.724} \times 100\% \quad (4)$$

Persentase area terindikasi rusak sebesar 41,43% sehingga termasuk kategori rusak parah (>30%). Area kerusakan (merah) terpetakan pada permukaan daun yang dianalisis, yang menunjukkan bahwa integrasi YOLOv11-Segmentation (menentukan area daun) dan HSV Thresholding (mengidentifikasi karakteristik warna) dapat mengestimasi persentase area rusak berbasis piksel. Kategori ini merupakan pengelompokan berdasarkan persentase piksel yang memenuhi kriteria warna HSV, bukan diagnosis jenis penyakit tanaman.

3.5. Evaluasi Kuantitatif Estimasi Kerusakan

Evaluasi klasifikasi dilakukan pada 256 citra daun jagung dengan label aktual Sehat (116), Ada Kerusakan (61), dan Rusak Parah (79). Tabel berikut menyajikan confusion matrix untuk HSV murni dan YOLO+HSV. Baris menunjukkan label aktual, sedangkan kolom menunjukkan label prediksi. Citra yang tidak terdeteksi tidak dimasukkan ke dalam sel confusion matrix 3×3 dan dilaporkan secara terpisah.

Tabel 6. *Confusion Matrix* HSV Murni

HSV Murni	Prediksi Sehat	Prediksi Ada Kerusakan	Prediksi Rusak Parah
Aktual Sehat	115	1	0
Aktual Ada Kerusakan	3	57	1
Aktual Rusak Parah	0	29	49
Total	**118**	**87**	**50**

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

Satu citra pada metode HSV murni tidak menghasilkan prediksi dan berasal dari kelas aktual Rusak Parah. Untuk YOLO+HSV, sebanyak 36 citra tidak terdeteksi: 7 citra aktual Sehat, tidak ada citra aktual Ada Kerusakan, dan 29 citra aktual Rusak Parah. Kegagalan tersebut tetap diperhitungkan sebagai kesalahan pada penghitungan metrik keseluruhan.

Tabel 7. *Confusion Matrix* YOLO+HSV

YOLO+HSV	Prediksi Sehat	Prediksi Ada Kerusakan	Prediksi Rusak Parah
Aktual Sehat	105	4	0
Aktual Ada Kerusakan	0	60	1
Aktual Rusak Parah	0	11	39
Total	105	75	40

Ringkasan metrik klasifikasi dihitung terhadap seluruh 256 citra, dengan citra tidak terdeteksi diperlakukan sebagai kegagalan pada kelas aktual. Precision, Recall, dan F1-score per kelas ditampilkan pada Tabel berikut.

Tabel 8. Precision, Recall, dan F1-score per Kelas

Metode / Kelas	Precision	Recall	F1-score
HSV murni – Sehat	97,46%	99,14%	98,29%
HSV murni – Ada Kerusakan	65,52%	93,44%	77,03%
HSV murni – Rusak Parah	98,00%	62,03%	75,97%
YOLO+HSV – Sehat	100,00%	90,52%	95,02%
YOLO+HSV – Ada Kerusakan	80,00%	98,36%	88,24%
YOLO+HSV – Rusak Parah	97,50%	49,37%	65,55%

Secara keseluruhan, HSV murni memperoleh akurasi 86,33%, macro Precision 86,99%, macro Recall 84,87%, dan macro F1-score 83,76%. YOLO+HSV memperoleh akurasi 79,69%, macro Precision 92,50%, macro Recall 79,41%, dan macro F1-score 82,93%. Dengan demikian, YOLO+HSV menghasilkan macro Precision lebih tinggi, tetapi HSV murni memperoleh akurasi, macro Recall, dan macro F1-score yang lebih tinggi pada kumpulan data uji ini.

Perbandingan ini merupakan evaluasi klasifikasi tingkat kerusakan pada citra, bukan pengukuran langsung jumlah piksel background noise yang berhasil dieliminasi. Karena tidak tersedia anotasi piksel manual khusus untuk area latar belakang dan lesi, penelitian ini belum dapat mengkuantifikasi pengurangan background noise secara pixel-level. Oleh sebab itu, manfaat operasi bitwise AND dijelaskan berdasarkan pembatasan spasial mask dan hasil visual, sedangkan bukti kuantitatifnya dibatasi pada metrik klasifikasi yang dilaporkan.

Tabel 9.Perbandingan Metrik Klasifikasi

Metrik	HSV Murni	YOLO+HSV
Jumlah citra uji	256	256
Prediksi berhasil	255	220
Tidak terdeteksi	1	36
Accuracy	86,33%	79,69%
Macro Precision	86,99%	92,50%
Macro Recall	84,87%	79,41%
Macro F1-score	83,76%	82,93%

Pada YOLO+HSV, Recall kelas Rusak Parah sebesar 49,37% merupakan nilai terendah. Dari 79 citra aktual Rusak Parah, 29 citra tidak terdeteksi dan 11 citra lain diprediksi sebagai Ada Kerusakan; hanya 39 citra diklasifikasikan dengan benar sebagai Rusak Parah. Hal ini menunjukkan bahwa rendahnya Recall kelas tersebut terutama berkaitan dengan kegagalan menemukan objek daun dan kekeliruan estimasi persentase kerusakan yang menyebabkan kategori turun menjadi Ada Kerusakan. Sebaliknya,

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

kelas Ada Kerusakan memiliki Recall 98,36%, sehingga sebagian besar citra kelas tersebut berhasil dikenali.

Tabel 10. Perbandingan Waktu Komputasi

Metrik komputasi	HSV murni	YOLO+HSV
Rata-rata latency	117,037 ms	251,187 ms
Median latency	134,015 ms	250,297 ms
FPS	8,544	3,981
Ukuran best.pt	Tidak menggunakan model YOLO	5,899 MB
Perangkat	CPU Google Colab	CPU Google Colab

Pengukuran waktu menunjukkan bahwa HSV murni memiliki latency rata-rata 117,037 ms, median 134,015 ms, dan sekitar 8,544 FPS. YOLO+HSV memiliki latency rata-rata 251,187 ms, median 250,297 ms, dan sekitar 3,981 FPS. Dengan konfigurasi pengukuran yang tercatat, penambahan tahap segmentasi YOLO meningkatkan waktu komputasi. Perbandingan ini perlu dibaca sesuai lingkungan CPU Google Colab yang digunakan; perubahan perangkat keras atau batas pengukuran waktu dapat menghasilkan angka berbeda.

Pemeriksaan kualitatif terhadap 36 citra yang tidak terdeteksi YOLO+HSV menemukan variasi kondisi visual, antara lain pencahayaan terlalu terang atau redup, refleksi dan bayangan, kontras daun dengan latar belakang yang rendah, objek terpotong atau terhalang, serta lesi atau pustul berukuran kecil. Berdasarkan kelompok nama file, 15 citra berasal dari kelompok RS_Rust, 7 dari R.S_HL, 6 dari Corn_Blight, 6 dari Corn_Gray_Spot, dan 2 dari kelompok RS_NLB/RS_GLSp. Pengelompokan nama file tersebut bukan distribusi kelas keparahan. Faktor-faktor visual yang dicatat merupakan dugaan berdasarkan pemeriksaan citra, bukan penyebab yang telah dibuktikan melalui eksperimen ablation. Oleh karena itu, hasil ini digunakan untuk menjelaskan karakteristik kasus gagal, bukan untuk menyatakan hubungan sebab-akibat.

Pada pemeriksaan visual terhadap sembilan citra contoh, mask daun HSV dinilai baik pada 1 dari 9 citra, sedangkan mask daun YOLO dinilai baik pada 6 dari 9 citra. Untuk mask kandidat kerusakan, penilaian baik tercatat pada 3 dari 9 citra HSV dan 7 dari 9 citra YOLO+HSV. Hasil sampel ini memberi indikasi kualitatif bahwa mask daun YOLO lebih konsisten daripada mask daun HSV pada sampel yang diperiksa. Namun, sembilan citra tersebut merupakan sampel ilustratif dan penilaian visual, bukan evaluasi kuantitatif berbasis anotasi piksel sehingga tidak dapat dipakai untuk menyimpulkan IoU, Dice, atau akurasi luas lesi.

3.6. Pembahasan dan Keterbatasan Penelitian

Integrasi YOLOv11-Segmentation dan HSV Thresholding berhasil diterapkan untuk menyegmentasi daun jagung serta mengestimasi persentase area terindikasi rusak. Pada pengujian 375 citra testing, model mencapai mask mAP@50 sebesar 87,80%, Recall 76,20%, dan mAP@50–95 sebesar 65,60%. Namun, pada uji klasifikasi 256 citra, akurasi metode gabungan YOLO+HSV (79,69%) masih berada di bawah HSV murni (86,33%) akibat kegagalan deteksi pada 14,06% sampel terutama pada kelas Rusak Parah (29 dari 79 citra) yang diduga berkaitan dengan pencahayaan tidak merata, refleksi, kontras rendah, serta objek yang terpotong.

Evaluasi ini juga memiliki tiga keterbatasan utama, pertama pemakaian anotasi otomatis berbasis OpenCV belum dikoreksi manual sehingga berisiko memicu circular annotation bias terhadap batas daun sebenarnya, kedua sensitivitas rentang warna HSV terhadap variasi pencahayaan dan tumpang tindih nilai Hue (30–35) membuat piksel daun sehat berpotensi ikut terhitung sebagai kerusakan, serta ketiadaan anotasi manual tingkat piksel dan validasi agronomis membuat akurasi luas kerusakan yang sebenarnya belum dapat dipastikan. Secara keseluruhan, sistem ini layak dijadikan pendekatan awal otomatisasi analisis citra daun jagung, tetapi pengembangan lanjutan tetap diperlukan melalui koreksi anotasi secara manual, pengujian Adaptive HSV atau segmentasi multi-kelas end-to-end, serta validasi terhadap pengukuran luas kerusakan independen. Karena pengukuran persentase kerusakan secara

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

manual pada citra uji belum tersedia, galat estimasi persentase (MAE atau RMSE) belum dapat dihitung dan menjadi agenda penelitian lanjutan.

4. KESIMPULAN

Penelitian ini mengembangkan sistem estimasi persentase area kandidat kerusakan daun jagung berbasis pengolahan citra dengan mengintegrasikan YOLOv11-Segmentation dan HSV Thresholding melalui operasi bitwise AND. Model yang dilatih selama 60 epoch dan dievaluasi pada 375 citra testing mencapai Precision 90,30%, Recall 78,20%, dan mAP@50 90,90% pada bounding box, serta Precision 86,40%, Recall 76,20%, mAP@50 87,80%, dan mAP@50–95 65,60% pada segmentation mask. Pada pengujian aplikasi, sistem mampu menghitung rasio kerusakan secara kuantitatif (seperti deteksi 42.556 piksel rusak dari 102.724 piksel daun atau 41,43% pada kategori rusak parah) dengan performa komputasi CPU sebesar 3,981 FPS (latency rata-rata 251,187 ms) dan ukuran model 5,899 MB. Meskipun integrasi ini berhasil membatasi penghitungan area rusak hanya pada objek daun, evaluasi klasifikasi terhadap 256 citra menunjukkan akurasi YOLO+HSV (79,69%; macro F1-score 82,93%) masih berada di bawah HSV murni (86,33%; macro F1-score 83,76%), salah satunya akibat 36 citra yang gagal terdeteksi.

Secara keseluruhan, sistem ini dapat digunakan sebagai pendekatan awal pengamatan kondisi daun jagung secara digital berbasis warna, bukan sebagai diagnosis penyakit tanaman. Penelitian ini masih memiliki sejumlah keterbatasan, yaitu penggunaan anotasi otomatis OpenCV tanpa koreksi manual menyeluruh yang berpotensi menimbulkan circular annotation bias, sensitivitas rentang HSV statis terhadap pencahayaan serta tumpang tindih rentang Hue (30–35), pelabelan klasifikasi yang belum melibatkan ahli agronomi independen, serta ketiadaan validasi pixel-level maupun pengukuran luas fisik secara manual sehingga nilai mAP segmentasi belum merepresentasikan akurasi luas kerusakan sebenarnya. Oleh karena itu, penelitian selanjutnya disarankan menggunakan anotasi mask yang dikoreksi manual, memperluas keragaman pencahayaan dan latar belakang citra, mengeksplorasi Adaptive HSV atau segmentasi multi-kelas end-to-end, serta membandingkan hasil estimasi sistem dengan pengukuran manual pada citra yang sama untuk menghitung galat pengukuran secara independen.

PERNYATAAN KONTRIBUSI PENULIS (CREDIT)

Muhammad Fadil Assalim: Penulisan – peninjauan dan penyuntingan, Penulisan – draf awal, Validasi, Perangkat lunak, Metodologi, Konseptualisasi. **Bala Wardana Putra**: Penulisan – draf awal, Analisis formal, Kurasi data, Konseptualisasi. **Vira Septiani**: Penulisan – draf awal, Perangkat lunak, Investigasi. **Rachmat Adi Purnama:** Penulisan – peninjauan dan penyuntingan, Supervisi. **Sujiliani Heristian:** Penulisan – peninjauan dan penyuntingan, Supervisi. **Veti Apriana**: Penulisan – peninjauan dan penyuntingan, Supervisi.

PERNYATAAN KONFLIK KEPENTINGAN

Para penulis menyatakan bahwa tidak terdapat kepentingan finansial atau hubungan pribadi yang diketahui yang dapat memengaruhi hasil penelitian yang dilaporkan dalam artikel ini.

PERNYATAAN PENDANAAN

Penulis tidak menerima dukungan finansial untuk penelitian, kepenulisan, dan/atau publikasi artikel ini.

PERNYATAAN PENGGUNAAN AI GENERATIF DAN TEKNOLOGI BERBANTUAN AI DALAM PROSES PENULISAN

Para penulis menggunakan ChatGPT (Versi *free*) sebagai alat bantu dalam proses penyusunan kerangka Metode Penelitian serta Hasil dan Pembahasan. Claude (Versi *free*) digunakan sebagai alat penyuntingan naskah untuk meningkatkan kejelasan bahasa, memperbaiki struktur penulisan, serta membantu penyempurnaan penyajian hasil penelitian. Selain itu, Gemini (Versi *plus*) digunakan sebagai alat bantu pembanding dalam proses pemeriksaan visual label aktual pada citra pengujian.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.457
Page 838-851

Seluruh hasil yang dihasilkan dengan bantuan teknologi AI telah ditinjau dan diverifikasi oleh penulis. Penulis bertanggung jawab sepenuhnya atas keakuratan data, analisis, interpretasi, dan isi akhir artikel yang dipublikasikan.

REFERENCES

[1] H. Albana and Z. Resti, "Tingkat Serangan Penyakit Karat Daun Pada Tanaman Jagung Manis Di Kecamatan Kuranji," *J. AGRIFOR*, vol. 23, no. 2, pp. 305–312, 2024, doi: 10.31293/agrifor.v23i2.7527.

[2] R. Meng *et al.*, "*Development of Spectral Disease Indices for Southern Corn Rust Detection and Severity Classification*," *Remote Sens.*, vol. 12, no. 19, p. 3255, 2020, doi: 10.3390/rs12193255.

[3] H. D. Mafukidze, G. Owomugisha, D. Otim, A. Nechibvute, C. Nyamhere, and F. Mazunga, "*Adaptive Thresholding of CNN Features for Maize Leaf Disease Classification and Severity Estimation*," *Appl. Sci.*, vol. 13, no. 4, p. 2077, 2022, doi: 10.3390/app13042077.

[4] M. A. Setyawan, P. Kasih, M. Ayu, and D. Widyadara, "Klasifikasi Penyakit Daun Jagung Berdasarkan Ruang Warna HSV dan Fitur Tekstur Dengan Algoritma K-NN," *Pros. Semin. Nas. Inov. Teknol.*, vol. 6, no. 3, pp. 67–72, 2022, doi: 10.29407/inotek.v6i3.2655.

[5] I. Wirabowo and I. Susilawati, "Implementasi *Convolution Neural Network* (CNN) untuk Deteksi Penyakit pada Daun Jagung Berbasis Citra Digital," *J. Pustaka Data*, vol. 5, no. 1, pp. 233–241, 2025, doi: 10.55382/jurnalpustakadata.v5i1.104.

[6] J. Kusuma, R. Rosnelly, and B. H. Hayadi, "Klasifikasi Penyakit Daun Pada Tanaman Jagung Menggunakan Algoritma *Support Vector Machine* , *K-Nearest Neighbors* dan *Multilayer Perceptron*," *JACOST*, vol. 4, no. 1, pp. 1–6, 2022, doi: 10.31326/jacost.v4i1.1578.

[7] D. S. Joseph, P. M. Pawar, and K. Chakradeo, "*Real-Time Plant Disease Dataset Development and Detection of Plant Disease Using Deep Learning*," *IEEE Access*, vol. 12, pp. 16310–16333, 2024, doi: 10.1109/ACCESS.2024.3358333.

[8] Z. Saeed, U. Nawaz, A. Raza, and K. Javed, "*Detection of Rice and Corn Plant Leaf Disease Using Invariants of Deep Learning Models and Edge Perspective*," *Artif. Intell. Appl.*, vol. 1, pp. 1–12, 2025, doi: 10.47852/bonviewAIA52025155.

[9] D. A. Pangestu, O. Q. Aziz, and C. Crysdian, "Klasifikasi Penyakit pada Tanaman Berdasarkan Citra Daun Menggunakan Metode *Convolutional Neural Network*," *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 10, no. 2, pp. 235–248, 2025, doi: 10.14421/jiska.2025.10.2.235-248.

[10] M. R. Lakehal, A. Mezenner, N. Arab, and H. Nemmour, "*Severity Estimation of Plant Leaf Diseases based on a CNN ensemble*," *AJSS (Algerian J. Signals Syst).*, vol. 8, no. 2, pp. 135–137, 2025, doi: 10.51484/ajss.v8i2.146.

[11] M. A. Pratama Putra and M. Fachrie, "Evaluasi Algoritma Deep Learning dan Segmentasi Klasik untuk Estimasi Luas serta Nilai Konstanta Daun Pepaya pada Sistem Smart Garden," *J. Algoritm.*, vol. 22, no. 2, pp. 789–798, 2025, doi: 10.33364/algoritma/v.22-2.2996.

[12] M. F. Farhat, S. Faisal, I. Sanjaya, A. Fauzi, and K. A. Baihaqi, "Analisis komparasi arsitektur efficientnetv2-s dan resnet50 dalam klasifikasi jenis dan tingkat keparahan penyakit daun padi," *JATI (Jurnal Mhs. Tek. Inform).*, vol. 10, no. 4, pp. 7073–7080, 2026, doi: 10.36040/jati.v10i4.18833.

[13] L. He, Y. Zhou, L. Liu, and J. Ma, "*Research and Application of YOLOv11-Based Object Segmentation in Intelligent Recognition at Construction Sites*," *Buildings*, vol. 14, no. 12, p. 3777, 2024, doi: 10.3390/buildings14123777.

[14] R. Sapkota and M. Karkee, "*Comparing YOLOv11 and YOLOv8 For Instance Segmentation Of Occluded and Non - Occluded Immature Green Fruits In Complex Orchard Environment*," 2026. doi: 10.48550/arXiv.2410.19869.

[15] E. Hamuda, B. M. Ginley, M. Glavin, and E. Jones, "*Automatic crop detection under field conditions using the HSV colour space and morphological operations*," *Comput. Electron. Agric.*, vol. 133, pp. 97–107, 2017, doi: 10.1016/j.compag.2016.11.021.

[16] L. He, X. Cheng, A. Jiwa, D. Li, J. Fang, and Z. Du, "*Zanthoxylum bungeanum Fruit Detection by Adaptive Thresholds in HSV Space for an Automatic Picking System*," *IEEE Sens. J.*, vol. 23, no. 13, pp. 14471–14486, 2023, doi: 10.1109/JSEN.2023.3277042.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/