

Deteksi Penyakit Daun Tanaman Stroberi Menggunakan Yolov8 Pendekatan Berbasis Deep Learning Di Tawangmangu

Efi Mukaromah^{1*}, Fauzan Masykur¹, Adi Fajaryanto Cobantoro¹

¹Program Studi Teknik Informatika, Fakultas Teknik

Universitas Muhammadiyah Ponorogo

Jl. Budi Utomo No.10 Ponorogo

INDONESIA

*Corresponding Author Email : evimukaromah1@gmail.com

Abstract: - Early detection of strawberry leaf diseases is crucial for enhancing agricultural productivity in highland areas such as Tawangmangu. This study aims to develop and evaluate the performance of the YOLOv8 model, to detect five major classes of strawberry leaf conditions in real time. A local dataset was collected directly from strawberry farms in Tawangmangu and annotated in YOLO format. The training process involved data augmentation and partitioning, followed by evaluation using accuracy, precision, recall, F1-score, and mean Average Precision (mAP) metrics. Model evaluation on the Google Colab platform yielded outstanding performance, with mAP@0.5 reaching 99.2% and mAP@0.5:0.95 recorded at 94.5%. Field testing using the STROBIKA websites demonstrated an average accuracy of 84.6%, effectively identifying the three main strawberry leaf diseases (Leaf Blight, Leaf Spot, and Tipburn) quickly and accurately. Despite challenges in classifying healthy leaves and non-strawberry objects, the system shows high potential for real-world agricultural implementation using deep learning technologies.

Keywords: deep learning, leafblight, leafspot, real-time detection, strawberry leaf disease, strobika, tawangmangu, tipburn, yolov8.

Received : July 21, 2025. Revised: July 27, 2025. Accepted: July 30, 2025. Published: August 10, 2025

1 Pendahuluan

Stroberi (*Fragaria spp.*) merupakan golongan tanaman dari keluarga *Rosaceae*, dan genus *Fragaria*[1]. Dalam studi yang dilakukan oleh A. M. Patel dkk (2022), menunjukkan bahwa stroberi berkontribusi signifikan terhadap peningkatan nilai ekonomi di sektor pertanian[2]. Di Indonesia, budidaya stroberi dimulai pada awal tahun 2000-an dan telah mengalami pertumbuhan pesat didorong dengan tingginya permintaan di pasar lokal. Meskipun popularitas stroberi terus meningkat, produktivitasnya masih terbatas karena tanaman ini hanya dapat tumbuh optimal di dataran tinggi dengan suhu yang sejuk [3].

Tawangmangu sebuah kecamatan di Kabupaten Karanganyar, Jawa tengah, dikenal sebagai salah satu daerah yang potensial untuk budidaya stroberi. Mengutip dari Badan Pusat Statistik Kabupaten Karanganyar, berlokasi di ketinggian sekitar 1.200 meter di atas permukaan laut dan memiliki suhu rata-rata berkisar antara 18–24°C, wilayah ini memiliki iklim sejuk yang sangat ideal untuk pertumbuhan tanaman stroberi. Dengan luas wilayah sebesar 70,03 km² yang terbagi dalam 10 desa, Tawangmangu tidak hanya menjadi kawasan wisata yang populer tetapi juga sentra penghasil stroberi lokal. Kombinasi kondisi geografis, iklim sejuk, dan suhu yang stabil menjadikan Tawangmangu salah satu daerah utama dalam mendukung permintaan stroberi lokal yang terus meningkat [4].

Meskipun popularitasnya terus berkembang, budidaya stroberi di Indonesia masih menghadapi beberapa kendala seperti penggunaan teknik budidaya konvensional. Keterbatasan ini menyebabkan hasil yang diperoleh belum dapat memenuhi permintaan pasar. Selain itu, kesulitan dalam penyediaan tanaman berkualitas tinggi dan bebas dari penyakit juga menjadi tantangan besar [5]. Sebagaimana dijelaskan oleh J.Xiao dkk (2021), tanaman stroberi (*Fragaria spp.*) sering kali mudah terinfeksi oleh beberapa patogen seperti jamur, bakteri, dan virus fitopatogenik [6].

Deteksi dini terhadap penyakit daun pada tanaman stroberi merupakan hal mendesak untuk meningkatkan produktivitas pertanian di daerah dataran tinggi seperti Tawangmangu Model deep learning seperti YOLO (*You Only Look Once*) telah terbukti efektif untuk deteksi objek secara real-time [7]. YOLO (*You Only Look Once*) merupakan evolusi dari pendekatan Convolutional Neural Network (CNN) yang dirancang untuk mendeteksi objek melalui model terpadu yang telah dilatih sebelumnya. Cobantoro dkk. (2023) menyebutkan bahwa CNN memiliki kemampuan konvolusional berlapis yang memungkinkan pengambilan fitur penting dari gambar secara bertahap, mulai dari pola dasar hingga representasi kompleks [8]. Namun, proses komputasi berlapis pada CNN tradisional sering kali membutuhkan waktu pemrosesan yang lebih lama, sehingga kurang ideal untuk aplikasi waktu nyata.

Sebagai solusi atas keterbatasan tersebut, YOLO mengadopsi pendekatan regresi satu tahap yang secara bersamaan memprediksi lokasi dan kelas objek tanpa proses seleksi wilayah sebelumnya. Pendekatan ini dinilai sangat cocok untuk mendeteksi

objek dalam skenario yang dinamis, seperti diagnosis penyakit tanaman langsung di lapangan. Hal ini sejalan dengan penelitian Viswanatha dkk. (2022) yang mendukung efektivitas YOLO dengan menyatakan bahwa algoritma ini mampu menganalisis seluruh gambar secara menyeluruh, bukan hanya potongan-potongan gambar terpisah [9]. Lebih lanjut, Masykur dkk. (2024) membuktikan bahwa YOLO versi 4 dapat mengidentifikasi area tanaman yang terinfeksi secara akurat dari citra drone, dan bahkan dapat diintegrasikan dengan sistem pemetaan spasial untuk menghasilkan data visual yang detail dan informatif [10].

Penelitian oleh Pranata dkk (2023). mengembangkan metode deteksi penyakit stroberi menggunakan YOLO dan teknik K-Fold Cross-Validation dengan dataset berupa lebih dari 3.200 citra daun, buah, dan bunga stroberi. Mereka memperoleh nilai *precision* perfect (1,00), *recall* 0,94, *F1-score* 0,84, dan *mean average precision* (mAP) sebesar 0,885 [1]. Hasil ini menunjukkan potensi tinggi YOLO di konteks deteksi penyakit tanaman stroberi.

Perbandingan antara YOLOv8 dengan YOLOv5 dalam studi pendeteksian penyakit daun tomat menunjukkan bahwa YOLOv8 memiliki tingkat *precision* dan *recall* yang lebih tinggi serta waktu inferensi lebih cepat berupa, nilai presisi YOLO8m 0.95% selisih 0.02% dengan YOLOv5m dan mAP50:95 yaitu 0.92% selisih 0.02% dengan YOLOv5m [7].

Studi global mengenai segmentasi YOLOv8 di lingkungan lapangan terbuka (open field) menunjukkan performa mAP hingga 80-an persen untuk segmentasi buah stroberi matang dan belum

matang, dengan waktu inferensi sekitar 12–24 ms, menunjukkan bahwa model ini memang *feasible* digunakan di kondisi lapangan pertanian realtime[11]

Penelitian lain yang membandingkan YOLO dan Mask R-CNN pada lingkungan kebun apel juga menemukan YOLO unggul baik dalam *precision* (~0,90–0,93) dan *recall* (~0,95–0,97), serta lebih efisien secara komputasi, mendukung pilihan YOLOv8 sebagai arsitektur deteksi efektif di pertanian berbasis citra 2D [12].

Penerapan YOLO di Indonesia belum banyak dikaji pada tanaman lokal seperti stroberi, namun hasil studi pada daun durian memperlihatkan bahwa sistem dapat mendeteksi daun sehat dan penyakit secara andal dengan akurasi tinggi, memudahkan petani lokal dalam deteksi cepat dan berbasis smartphone maupun laptop berbasis cloud atau lokal[13].

Variasi penelitian pertanian di Indonesia yang memadukan deep learning dan agrikultur juga menunjukkan peluang besar dalam memaksimalkan hasil panen melalui deteksi penyakit canggih berbasis citra daun. Model YOLO yang sudah dioptimalkan melalui augmentasi data dan pembagian data yang baik (misalnya K-Fold) memiliki kemampuan untuk diadaptasi di wilayah seperti Tawangmangu yang memiliki cahaya variatif dan latar belakang visual khas pegunungan.

Dengan latar belakang ini, penelitian dalam konteks lokal Tawangmangu bertujuan menyesuaikan dan menguji langsung Algoritma YOLOv8 terhadap dataset daun stroberi yang dikumpulkan di lokasi lapangan. Pendekatan ini

diharapkan dapat memberikan solusi deteksi penyakit daun stroberi yang andal, cepat, dan praktis bagi petani di Tawangmangu.

2 Rumusan Masalah

Masalah utama dalam penelitian ini berpusat pada kebutuhan metode yang dapat mendeteksi penyakit daun stroberi secara otomatis dan akurat [14], di lingkungan lapangan seperti Tawangmangu. Penelitian terdahulu oleh Pranata dkk. menggunakan YOLOv8 dengan K-Fold *Cross-Validation* pada dataset berkelas penyakit stroberi, yang menunjukkan akurasi mAP sebesar 0,885 dan *precision* mencapai 1,00 serta *recall* 0,94[1]. Namun, sebagian besar penelitian dilakukan di laboratorium atau lingkungan buatan, dan belum menyesuaikan kondisi lapangan Tawangmangu yang memiliki pencahayaan variatif serta varietas stroberi lokal dengan bentuk daun yang berbeda.

Tantangan teknis seperti pencahayaan yang tidak seragam, perbedaan sudut pengambilan gambar, serta heterogenitas visual daun stroberi menjadi aspek penting yang perlu dipertimbangkan. Dalam upaya mengembangkan sistem deteksi penyakit daun stroberi yang akurat dan adaptif terhadap kondisi lapangan, diperlukan evaluasi menyeluruh terhadap performa algoritma YOLOv8 dalam menghadapi tantangan visual di lingkungan pertanian dataran tinggi. Sehingga rumusan masalah dalam penelitian ini mencakup, seberapa akurat model YOLOv8 dalam mendeteksi penyakit daun stroberi dan bagaimana kinerja implementasi YOLOv8 dalam mendeteksi penyakit daun stroberi pada kondisi lapangan di Tawangmangu.

3 Solusi Masalah

Penelitian ini mengusulkan penerapan model YOLOv8s untuk mendeteksi penyakit daun stroberi secara otomatis di wilayah pertanian Tawangmangu. YOLOv8s merupakan varian ringan dari keluarga YOLO yang dirancang untuk memberikan keseimbangan antara kecepatan dan akurasi, sehingga cocok digunakan pada perangkat dengan keterbatasan komputasi. Model ini bekerja secara satu tahap (*one-stage detector*) dan mampu mendeteksi objek secara real-time, menjadikannya efektif untuk kondisi lapangan yang dinamis.

Untuk penerapan konkret di Tawangmangu, tahap pengumpulan dan anotasi dataset lokal dilakukan langsung di lapangan, mencakup berbagai kondisi pencahayaan dan sudut pengambilan gambar. Data daun stroberi yang sehat maupun terinfeksi berbagai jenis penyakit dikumpulkan dan dianotasi dalam format YOLO menggunakan tool seperti Roboflow. Teknik augmentasi data seperti rotasi, flip, perubahan kecerahan, dan mosaic digunakan untuk meningkatkan variasi dataset dan mencegah overfitting, sebagaimana disarankan dalam literatur YOLO terkini untuk memperbaiki generalisasi model [15].

Pelatihan model dilakukan dengan membagi dataset ke dalam subset training, validasi, dan testing (misalnya 70% : 20% : 10%), dilanjutkan dengan pencarian hiperparameter yang optimal seperti *batch size*, *epoch*, dan *image size*. Hasil evaluasi metrik seperti *precision*, *recall*, *F1-score*, dan *mAP* ditampilkan dan dianalisis. Kemudian model YOLO yang memenuhi kriteria dapat diimplementasikan ke sistem untuk dilakukan pengujian secara realtime.

4 Hasil dan Pembahasan

Pengujian Model YOLO

Pengujian model YOLOv8 dilakukan untuk mengukur kinerja deteksi objek, khususnya dalam mendeteksi penyakit pada tanaman stroberi. Dalam evaluasi ini, beberapa metrik utama yang digunakan untuk menilai hasil pelatihan model antara lain *Precision*, *Recall*, *F1-Score*, dan *mAP* (*mean Average Precision*) pada *threshold IoU*.

Rumus yang digunakan dalam melakukan perhitungan berbasis confusion matrix adalah sebagai berikut [16] [17]:

$$recall = \frac{TP}{TP + FN} \quad (1)$$

$$precision = \frac{TP}{TP + FP} \quad (2)$$

$$F1\ Score = 2 \times \frac{precision \times recall}{precision + recall} \quad (3)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (5)$$

Keterangan :

1. *Recall* : mengukur kemampuan model untuk mendeteksi semua objek yang benar (sensitivitas).
2. *Precision*: mengukur akurasi prediksi positif model dalam mendeteksi objek
3. *F1 Score*: rata-rata harmonis antara *precision* dan *recall*, memberikan keseimbangan di antara keduanya.
4. *mAP* : rata-rata dari nilai *Average Precision* (AP) yang dihitung untuk setiap kelas objek
5. *TP* : True Positive (prediksi benar sebagai objek)
6. *FP* : False Positive (prediksi salah sebagai objek)
7. *FN*: False Negative (objek yang ada namun tidak terdeteksi)
8. *n* : jumlah titik *recall* yang dihitung.
9. *Precision*(r_i) : Presisi pada titik r_i
10. *N* : jumlah kelas (berbagai jenis objek yang dideteksi).
11. AP_i : nilai *Average Precision* untuk kelas ke- i
12. *Accuracy* : Tingkat akurasi yang diperoleh model selama training


Pengujian model YOLO bertujuan untuk mengevaluasi kemampuannya dalam menggeneralisasi pola dari data latih ke data uji yang belum pernah dilihat sebelumnya. Evaluasi dilakukan menggunakan data uji yang telah dipisahkan sejak awal, dengan tujuan menghindari bias serta untuk menggambarkan performa model secara objektif dalam mendeteksi dan mengklasifikasikan objek. Dalam proses pengujian ini, model diuji terhadap lima kelas utama daun, yaitu Bercak Daun, Bukan

Daun Stroberi, Daun Sehat, Hawar Daun, dan Tipburn.



Gambar 1 Grafik Confusion Matrix Pengujian Model YOLOv8

Perhitungan akurasi dari *confusion matrix* dilakukan dengan menggunakan rumus yang ditunjukkan pada persamaan, berikut ini.




Gambar 2 Rumus Confusion Matrix

Keterangan:


- True Positive (TP)* : Sampel data positif, prediksi positif
- True Negative (TN)* : Sampel data negatif, prediksi negatif
- False Positive (FP)* : Sampel data negatif, prediksi positif
- False Negatif (FN)* : Sampel data positif, prediksi negatif

Evaluasi pertama dilakukan melalui confusion matrix, yang menunjukkan akurasi tiap kelas berdasarkan kombinasi *True Positive (TP)*, *False Positive (FP)*, *False Negative (FN)*, dan *True Negative (TN)*. Hasil akurasi menunjukkan performa sangat baik dengan nilai di atas 97% untuk semua kelas. Kelas Bukan Daun Stroberi mencatat akurasi tertinggi sebesar 99,74%, diikuti oleh Hawar Daun sebesar 99,47%, Bercak Daun sebesar 99,21%, Tipburn sebesar 99,07%, dan Daun Sehat sebesar 97,22%. Ini menunjukkan bahwa model mampu mengenali objek dari masing-masing kelas dengan sangat akurat dan konsisten, walaupun masih terdapat sedikit kesalahan klasifikasi.



Gambar 3 Grafik *Precision-confidence curve* YOLOv8


Selanjutnya, evaluasi dilanjutkan dengan grafik *Precision-Confidence Curve* untuk menilai tingkat ketepatan prediksi model pada berbagai ambang kepercayaan. Hasil *precision* menunjukkan bahwa semua kelas memiliki nilai *precision* di atas 91%, dengan Bukan Daun Stroberi memperoleh *precision* sempurna sebesar 100%. Hal ini berarti bahwa tidak ada prediksi yang salah untuk kelas tersebut. *Precision* terendah dicapai oleh kelas Daun Sehat (91,3%), akibat adanya false positive. Grafik *Precision-Confidence Curve* memperlihatkan bahwa nilai *precision* meningkat seiring naiknya confidence threshold dan mencapai titik tertinggi pada nilai sekitar 0.995.



Gambar 4 Grafik *Recall-Confidence Curve* YOLOv8


Evaluasi berikutnya dilakukan dengan grafik *Recall-Confidence Curve* untuk menilai sensitivitas model dalam mengenali semua sampel positif. Kelas Hawar Daun menunjukkan *recall* sempurna (100%), diikuti oleh Bercak Daun dan Tipburn yang juga memiliki nilai tinggi di atas 97%. Nilai *recall* cenderung menurun ketika confidence threshold semakin tinggi karena model menjadi lebih selektif. Grafik ini menunjukkan pentingnya pengaturan

ambang yang tepat agar model tetap sensitif terhadap seluruh kasus penting dalam pengujian nyata.



Gambar 5 Grafik F1-Confidence Score YOLOv8

Grafik *F1-Confidence Curve* digunakan untuk menilai keseimbangan antara *precision* dan *recall* pada tiap kelas. Hasil perhitungan menunjukkan bahwa semua kelas memiliki F1 Score tinggi, dengan Tipburn mencatat nilai tertinggi sebesar 98,1%, dan Daun Sehat dengan nilai terendah sebesar 94,7%. Nilai *F1 Score* tetap stabil di berbagai level *confidence threshold*, dan mencapai puncaknya pada ambang kepercayaan sekitar 0.454. Stabilitas ini menunjukkan bahwa model tidak hanya akurat, tetapi juga konsisten dalam berbagai situasi prediksi.



Gambar 6 Grafik *Precision-Recall* curve

Selanjutnya, grafik *Precision-Recall Curve* menunjukkan hubungan langsung antara ketepatan dan sensitivitas model, tanpa dipengaruhi oleh ketidakseimbangan jumlah data antar kelas. Hasil evaluasi menunjukkan bahwa setiap kelas memiliki nilai *Average Precision (AP)* di atas 99%, yang menandakan bahwa model memiliki kemampuan sangat baik dalam mendeteksi objek meskipun distribusi data tidak merata. Perhitungan *mAP (mean Average Precision)* model mencapai 99,24%, yang menjadi indikator kuat bahwa model dapat mendeteksi dan mengklasifikasikan objek dengan tingkat kesalahan yang sangat rendah.

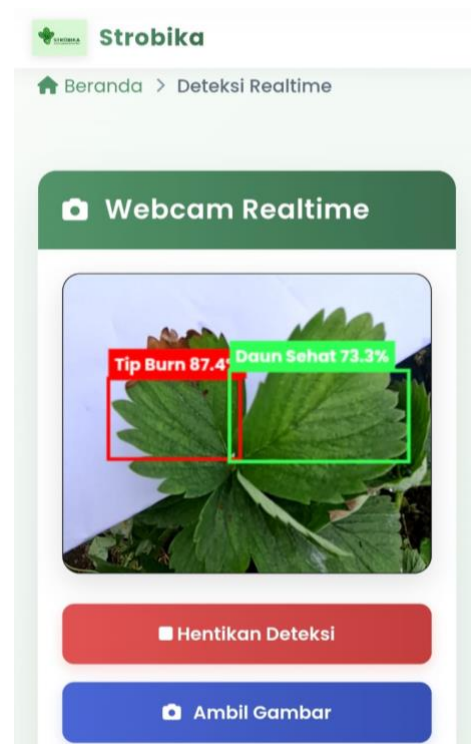
Secara keseluruhan, hasil pengujian model YOLOv8 menunjukkan performa yang sangat tinggi dan stabil dalam klasifikasi lima kelas utama daun. Hal ini terlihat dari nilai akurasi, *precision*, *recall*, *F1 Score*, dan *mAP* yang tinggi dan konsisten. Model terbukti mampu mengklasifikasikan objek dengan presisi tinggi dan sensitivitas optimal, sehingga sangat layak digunakan dalam aplikasi deteksi objek berbasis deep learning di bidang pertanian, khususnya untuk mendeteksi penyakit atau kerusakan daun.

Performa optimal pada berbagai metrik evaluasi membuktikan bahwa YOLOv8 tidak hanya mampu mengenali objek dengan tepat, tetapi juga mempertahankan performa tersebut pada berbagai ambang kepercayaan. Hal ini memberikan fleksibilitas dalam penyesuaian model untuk kebutuhan tertentu, seperti sistem monitoring tanaman otomatis, klasifikasi daun sehat dan rusak, serta pengembangan aplikasi pertanian presisi. Dengan demikian, model YOLOv8 dapat menjadi

solusi efektif dan efisien dalam penerapan teknologi pada sektor agrikultur.

Pengujian Lapangan

Pengujian aplikasi deteksi penyakit daun stroberi menggunakan STROBIKA dilakukan secara langsung di lapangan, tepatnya di kebun stroberi milik salah satu petani yang berlokasi di Desa Gondosuli, Kecamatan Tawangmangu, Kabupaten Karanganyar, Jawa Tengah. Tujuan utama kegiatan ini adalah untuk menilai kinerja serta tingkat akurasi aplikasi dalam mengenali berbagai kondisi daun stroberi secara real-time di lingkungan pertanian sebenarnya. Selama pengujian, peneliti melakukan deteksi di berbagai titik dalam area perkebunan, Aplikasi STROBIKA mampu mengenali daun sehat dan tiga jenis penyakit utama yang umum menyerang tanaman stroberi di daerah tersebut, yaitu Hawar Daun (*Leaf Blight*), Bercak Daun (*Leaf Spot*), dan Tipburn. Ketiga penyakit ini diketahui disebabkan oleh infeksi virus serta gangguan fisiologis yang dipicu oleh faktor lingkungan seperti kelembaban tinggi, cuaca ekstrem, dan ketidakseimbangan nutrisi. Hal ini turut dibenarkan oleh Bapak Setya selaku petani dan pemilik kebun, yang menyatakan bahwa penyakit-penyakit tersebut merupakan ancaman serius bagi produktivitas tanamannya.



Gambar 7 Pengujian lapangan Deteksi realtime dengan website STROBIKA

Sebagai upaya pengendalian, para petani di wilayah ini biasa menggunakan pestisida berbahan aktif seperti mankozeb, klorotalonil, dan tembaga hidroksida, serta melakukan pemangkasan daun yang terinfeksi untuk mencegah penyebaran lebih lanjut. Hasil pengujian lapangan yang ditampilkan dalam Gambar 7 memperlihatkan kemampuan website dalam mendeteksi penyakit secara langsung melalui kamera perangkat, menampilkan label nama penyakit dan *bounding box* yang menunjukkan area daun yang terdampak. Untuk mengevaluasi akurasi sistem, dilakukan pengambilan sampel dari 15 gambar secara acak, yang kemudian diverifikasi langsung oleh petani. Tabel pengujian mencatat 42 hasil deteksi, yang mencakup lima klasifikasi utama: Hawar Daun, Tipburn, Bercak Daun, Daun Sehat, dan Bukan Daun Stroberi.

Setiap deteksi dilengkapi dengan *confidence score* atau tingkat keyakinan prediksi, dan dari hasil tersebut dihitung rata-rata kepercayaan tiap kelas. Hasilnya, deteksi untuk penyakit Hawar Daun menghasilkan rata-rata *confidence* sebesar 88,7% dari 6 deteksi, Tipburn sebesar 86,8% dari 11 deteksi, Bercak Daun sebesar 88,0% dari 5 deteksi, Daun Sehat sebesar 81,2% dari 16 deteksi, dan Bukan Daun Stroberi sebesar 82,0% dari 4 deteksi. Dengan demikian, akurasi rata-rata keseluruhan aplikasi dalam pengujian ini mencapai 84,6%, yang menunjukkan performa cukup andal untuk digunakan langsung oleh petani di lapangan dalam skala terbatas.

Meskipun hasilnya menjanjikan, pengujian juga mengungkap adanya beberapa kendala yang perlu diperhatikan, khususnya pada klasifikasi *Daun Sehat* dan *Bukan Daun Stroberi*, di mana sistem terkadang gagal mendeteksi atau melakukan klasifikasi secara keliru. Faktor-faktor seperti pencahayaan alami, keragaman bentuk daun, dan kemiripan visual antar jenis penyakit turut memengaruhi akurasi deteksi di lingkungan nyata.

Oleh karena itu, diperlukan peningkatan lebih lanjut, baik dari segi kualitas dan keragaman dataset pelatihan, penyesuaian arsitektur model, maupun optimalisasi proses inferensi agar sistem dapat bekerja lebih stabil dan adaptif terhadap kondisi lapangan yang dinamis. Secara keseluruhan, hasil pengujian ini menunjukkan bahwa pengembangan website STROBIKA berjalan ke arah yang positif dan memiliki potensi besar untuk diadopsi dalam sistem pertanian cerdas. Dengan pengembangan berkelanjutan, sistem ini dapat menjadi alat bantu yang efektif bagi petani dalam

meningkatkan efisiensi, mencegah kerusakan tanaman lebih lanjut, dan mendukung produktivitas pertanian berbasis teknologi di masa depan.

Kesimpulan

Hasil pelatihan model YOLOv8 menunjukkan performa yang sangat baik dalam mendeteksi penyakit daun stroberi, dengan nilai evaluasi $mAP@0.5$ sebesar 99,2% dan $mAP@0.5:0.95$ sebesar 94,5%, yang mencerminkan kemampuan model dalam melakukan deteksi dan klasifikasi dengan presisi tinggi pada data validasi yang terkontrol. Namun, saat diimplementasikan melalui website STROBIKA dan diuji langsung di lapangan, terjadi sedikit penurunan performa, ditunjukkan oleh rata-rata *confidence* prediksi yang hanya mencapai 84,6% pada 42 sampel data nyata, yang kemungkinan disebabkan oleh faktor lingkungan seperti pencahayaan tidak merata, latar belakang kompleks, atau variasi kondisi daun yang tidak sepenuhnya tercakup dalam data pelatihan. Meskipun demikian, hasil uji coba tetap menunjukkan bahwa sistem mampu memberikan deteksi yang cukup akurat secara realtime dan dapat membantu petani dalam proses identifikasi penyakit secara lebih cepat dan efisien, sehingga temuan ini menegaskan bahwa meskipun terdapat kesenjangan antara performa pelatihan dan implementasi, model tetap layak digunakan dalam konteks pertanian nyata dengan potensi peningkatan performa melalui penambahan data pelatihan dari kondisi nyata di lapangan.

Daftar Pustaka

- [1] I. M. D. Pranata, I. Darma, I. M. S. Sandhiyasa, Dan I. Wiguna, "Strawberry

- Disease Detection Based On Yolov8 And K-Fold Cross-Validation,” *Jurnal Ilmiah Merpati (Menara Penelitian Akademika Teknologi Informasi)*, Vol. 11, No. 3, 2023.
- [2] A. M. Patel, W. S. Lee, Dan N. A. Peres, “Imaging And Deep Learning Based Approach To Leaf Wetness Detection In Strawberry,” *Sensors*, Vol. 22, No. 21, Hlm. 8558, 2022.
- [3] S. Pertiwi, D. H. Wibowo, Dan S. Widodo, “Deep Learning Model For Identification Of Diseases On Strawberry (*Fragaria Sp.*) Plants,” *International Journal On Advanced Science, Engineering & Information Technology*, Vol. 13, No. 4, 2023.
- [4] B. P. S. K. Karanganyar, *Kecamatan Tawangmangu Dalam Rangka Tawangmangu District In Figures 2024*, Volume 38,. 2024. [Daring]. Tersedia Pada: <https://karanganyarkab.bps.go.id/id/publication/2024/09/26/f516155801c9e144ffc0ddb5/kecamatan-tawangmangu-dalam-angka-2024.html>
- [5] A. V Efrilla, S. B. Sulistyono, K. Wijaya, P. H. Kuncoro, Dan A. Sudarmaji, “Klasifikasi Penyakit Pada Daun Stroberi Menggunakan K-Means Clustering Dan Jaringan Syaraf Tiruan,” *Journal Of Tropical Agricultural Engineering And Biosystems-Jurnal Keteknik Pertanian Tropis Dan Biosistem*, Vol. 8, No. 2, Hlm. 161–170, 2020.
- [6] J.-R. Xiao, P.-C. Chung, H.-Y. Wu, Q.-H. Phan, J.-L. A. Yeh, Dan M. T.-K. Hou, “Detection Of Strawberry Diseases Using A Convolutional Neural Network,” *Plants*, Vol. 10, No. 1, Hlm. 31, 2020.
- [7] Siti Choiriyah Dan Aji Supriyanto, “Perbandingan Deep Learning Yolov5 Dan Yolov8 Untuk Deteksi Penyakit Daun Tanaman Tomat,” *Jitsi: Jurnal Ilmiah Teknologi Sistem Informasi*, Vol. 6, No. 1, Hlm. 56–65, Mar 2025, Doi: 10.62527/Jitsi.6.1.357.
- [8] A. Fajaryanto Cobantoro, ; Fauzan Masykur, Dan ; Kelik Sussolaikah, “Performance Analysis Of Alexnet Convolutional Neural Network (Cnn) Architecture With Image Objects Of Rice Plant Leaves,” *Jitk (Jurnal Ilmu Pengetahuan Dan Teknologi Komputer)*, Vol. 8, No. 2, Hlm. 117–122, Feb 2023, Doi: 10.33480/Jitk.V8i2.4060.
- [9] V. V, C. R.K, Dan R. A.C, “Real Time Object Detection System With Yolo And Cnn Models: A Review,” *Journal Of Xi An University Of Architecture & Technology Xiv(Vii)*, Vol. Xiv, No. 7, Hlm. 144–151, Jul 2022, Diakses: 20 Juli 2025. [Daring]. Tersedia Pada: https://www.researchgate.net/publication/361929615_real_time_object_detection_system_with_yolo_and_cnn_models_a_review
- [10] F. Masykur, A. Kusworo, Dan O. D. Nurhayati, “Measuring Agricultural Area Using Yolo Object Detection And Aruco Markers - Proquest,” *International Information And Engineering Technology Association (Iieta)*, Vol. 29, No. 1, Hlm. 95–106, Feb 2024, Diakses: 20 Juli 2025. [Daring]. Tersedia Pada: <https://www.proquest.com/openview/eade87a0fba100e77c01a55e2387497a/1?pq-origsite=gscholar&cbl=2069459>
- [11] A.-R. A. Gamani, I. Arhin, Dan A. K. Asamoah, “Performance Evaluation Of Yolov8 Model Configurations, For Instance Segmentation Of Strawberry Fruit Development Stages In An Open Field Environment,” Agu 2024, Diakses: 20 Juli 2025. [Daring]. Tersedia Pada: <http://arxiv.org/abs/2408.05661>
- [12] A. F. Cobantoro, F. Masykur, Dan M. R. Rosyadi, “Implementation Of Bot Telegram As Broadcasting Media Classification Results Of Convolutional Neural Network (Cnn) Images Of Rice Plant Leaves,” *Journal Of Computer Networks, Architecture And High Performance Computing*, Vol. 5, No. 1, Hlm.

1–9, Jan 2023, Doi:
10.47709/Cnahpc.V5i1.1976.

- [13] R. R. Putra, M. Maimunah, Dan D. Sasongko, “Implementasi Algoritma Yolo V8 (*You Only Look Once*) Dalam Deteksi Penyakit Daun Durian,” *Building Of Informatics, Technology And Science (Bits)*, Vol. 6, No. 3, Hlm. 1517–1526-1517–1526, Des 2024, Doi: 10.47065/Bits.V6i3.6136.
- [14] Y. Sonata, S. B. Sulistyono, Dan K. Wijaya, “Deteksi Dini Penyakit Pada Daun Stroberi Berbasis Pengolahan Citra Early Detection Of Disease In Strawberry Leaves Based On Image Processing,” *Jaber: Journal Of Agricultural And Biosystem Engineering Research*, Vol. 1, No. 2, Hlm. 29–40, 2020, [Daring]. Tersedia Pada: [Http://Jos.Unsoed.Ac.Id/Index.Php/Jaber/](http://jos.unsoed.ac.id/index.php/jaber/)
- [15] M. Shahriar Zaman Abid, B. Jahan, A. Al Mamun, M. Jakir Hossen, Dan S. Hossain Mazumder, “Bangladeshi Crops Leaf Disease Detection Using Yolov8,” *Heliyon*, Vol. 10, No. 18, Sep 2024, Doi: 10.1016/J.Heliyon.2024.E36694.
- [16] I Made Dicky Pranata, I Wayan Agus Surya Darma, I Made Subrata Sandhiyasa, Dan I Komang Arya Ganda Wigunaa, “Strawberry Disease Detection Based On Yolov8 And K-Fold Cross-Validation,” *Jurnal Ilmiah Merpati*, Vol. Vol. 11, No. 3, Hlm. 199–210, Des 2023.
- [17] M. Anwar, Y. Kristian, Dan E. Setyati, “Classification Of Chili Plant Diseases Equipped With Leaf And Fruit Image Segmentation Using Yolo V7,” *Journal Of Information Technology And Computer Science (IntecomS)*, Vol. 6, No. 1, 2023.