

Klasifikasi Penyakit Early Blight dan Late Blight pada Daun Tomat dengan YOLOv8

Classification of Early Blight and Late Blight Diseases on Tomato Leaves with YOLOv8

Dodi Dwi Riskianto^{1*}, Ahmad Rico Mardiansyah², Ahmad Supriadi³

^{1,2,3}Teknik Informatika, Teknik, Universitas Nurul Jadid, Probolinggo, Indonesia

*E-mail: dwidr07@gmail.com, ricomardiansyah27@gmail.com, ahmadsupriadi@unuja.ac.id

Article History

Submitted : Mei 20, 2026
Revised : Juni 12, 2026
Accepted : Juli 2, 2026
Available Online : Juli 31, 2026
Published Regularly : Juli 31, 2026

Kata Kunci: YOLOv8, Penyakit Tumbuhan, Pertanian Tomat, Deep Learning, Computer Vision

Keywords: YOLOv8, Plant Diseases, Tomato Agriculture, Deep Learning, Computer Vision

Contact



Author

dwidr07@gmail.com

ABSTRAK

Penyakit pada daun tomat merupakan masalah utama dalam pertanian di Indonesia yang dapat menurunkan hasil panen secara signifikan. Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit daun tomat menggunakan YOLOv8, sebuah arsitektur deteksi objek yang cepat dan akurat.

Dataset dalam penelitian ini diklasifikasikan ke dalam beberapa kelas, yaitu Healthy, Bacterial Spot, Early Blight, dan Black Spot. Proses preprocessing meliputi augmentasi data dan pelabelan (labelling) untuk meningkatkan performa model serta mencegah overfitting selama proses pelatihan.

Evaluasi kinerja model dilakukan menggunakan metrik mAP, akurasi, F1-score, dan confusion matrix. Hasil pengujian menunjukkan bahwa model YOLOv8 mencapai nilai rata-rata F1-score sebesar 0.72 pada tingkat confidence optimal 0.506, dengan performa pendeteksian terbaik terdapat pada kelas Healthy. Namun, kelas seperti Bacterial Spot dan Black Spot masih menunjukkan tingkat kesalahan akibat adanya tumpang tindih fitur visual antar kelas.

Analisis confusion matrix mengindikasikan perlunya peningkatan distribusi data dan penggunaan fitur yang lebih representatif untuk meningkatkan akurasi. Secara keseluruhan, penelitian ini menunjukkan potensi model YOLOv8 untuk klasifikasi penyakit daun tomat secara real-time. Optimalisasi melalui penyeimbangan dataset (dataset balancing), augmentasi yang lebih beragam, dan proses fine-tuning pada model diperlukan untuk meningkatkan sensitivitas. Model ini memiliki potensi besar untuk diterapkan pada perangkat berbasis Internet of Things (IoT) guna mendukung kemajuan sektor pertanian di Indonesia.

ABSTRACT

Diseases on tomato leaves are a major problem in agriculture in Indonesia that can significantly reduce crop yields. This study aims to develop a tomato leaf disease classification model using YOLOv8, a fast and accurate object detection architecture.

The dataset in this study is classified into several classes, namely Healthy, Bacterial Spot, Early Blight, and Black Spot. The preprocessing process includes data augmentation and labeling to improve model performance and prevent overfitting during the training process.

The model's performance evaluation was conducted using mAP, accuracy, F1-score, and confusion matrix metrics. The test results show that the YOLOv8 model achieved an average F1-score of 0.72 at an optimal confidence level of 0.506, with the best detection performance found in the Healthy class. However, classes such as Bacterial Spot and Black Spot still show error rates due to overlapping visual features between classes.

The confusion matrix analysis indicates the need to improve data distribution and use more representative features to improve accuracy. Overall, this study demonstrates the potential of the YOLOv8 model for real-time tomato leaf disease classification. Optimization through dataset balancing, more diverse augmentation, and fine-tuning the model is needed to improve sensitivity. This model has great potential to be implemented on Internet of Things (IoT) based devices to support the progress of the agricultural sector in Indonesia.

1. Pendahuluan

Produktivitas sektor pertanian di Indonesia menghadapi tantangan yang signifikan, terutama akibat penyakit tanaman yang dapat menyebabkan penurunan hasil panen secara drastis [1]. Penyakit seperti Early Blight dan Late Blight pada tomat, misalnya, menjadi ancaman serius bagi petani di daerah sentra produksi utama [2], seperti Jawa dan Sumatra. Berdasarkan laporan Kementerian Pertanian, kerugian hasil panen akibat penyakit ini dapat mencapai 20–30% dari total produksi, yang berdampak langsung pada pendapatan petani dan pasokan pangan nasional [3]. Oleh karena itu, kemampuan untuk mendeteksi dan mengklasifikasi penyakit tanaman secara dini penting guna mendukung produktivitas pertanian dan menjaga ketahanan pangan di Indonesia.

Kemajuan teknologi, khususnya dalam bidang kecerdasan buatan, telah membuka peluang baru dalam mendeteksi dan mengklasifikasi penyakit tanaman dengan lebih cepat dan akurat [4]. Salah satu tantangan utama adalah mengembangkan model yang mampu memproses data visual dalam skala besar secara *real-time* untuk mengidentifikasi pola penyakit dengan presisi tinggi. Hal ini sangat penting untuk memungkinkan tindakan pencegahan atau pengobatan yang tepat waktu, sehingga kerugian dapat diminimalkan [5].

Penelitian terdahulu telah mengeksplorasi penggunaan *deep learning* dalam mendeteksi penyakit tanaman melalui analisis citra daun. *Deep Learning* telah meraih kesuksesan besar di banyak aplikasi terapan dalam computer vision [6]. Misalnya, penelitian oleh [7] menggunakan

model Convolutional Neural Network (CNN) untuk mendeteksi beberapa jenis penyakit tanaman dengan membaca perubahan pada daun. Selain itu, penelitian oleh [8] menunjukkan bahwa algoritma berbasis CNN dapat memberikan akurasi tinggi dalam klasifikasi penyakit tanaman, terutama pada *dataset* yang terstruktur dengan baik. Di sisi lain, [9] memanfaatkan algoritma YOLOv5 untuk mendeteksi objek tanaman di mana peneliti mendeteksi penyakit bercak pada daun dengan pelatihan model yang lebih ringan dan sudah dioptimalkan. Namun, penelitian-penelitian ini sering kali memiliki keterbatasan dalam hal kecepatan pemrosesan dan kemampuan untuk mengenali gejala untuk beberapa objek tanaman yang cukup kompleks.

Untuk mengatasi keterbatasan ini, solusi yang diusulkan adalah dengan menggunakan YOLOv8, algoritma terbaru dalam deteksi objek *real-time*, yang menawarkan peningkatan kecepatan dan akurasi dibandingkan versi sebelumnya [10]. Selain itu, model yang dikembangkan dirancang untuk mengklasifikasi penyakit Early Blight dan Late Blight pada daun tomat dengan pendekatan berbasis visual yang inovatif [11]. Dengan memanfaatkan YOLOv8, penelitian ini diharapkan mampu memberikan solusi yang lebih cepat, lebih tepat, dan lebih andal dalam mendukung pengambilan keputusan di sektor pertanian [12].

Tujuan dari penelitian ini adalah untuk mengembangkan model deteksi dan klasifikasi penyakit Early Blight dan Late Blight pada daun tomat dengan menggunakan YOLOv8. Model ini dirancang untuk meningkatkan efisiensi pemrosesan dan akurasi dalam pengenalan penyakit tanaman secara lebih cepat, sehingga dapat memberikan dampak positif pada pengelolaan pertanian yang berkelanjutan.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan berbasis pengenalan pola citra daun dengan dukungan teknologi *deep learning* untuk mendeteksi Early Blight dan Late Blight pada daun tomat. Tahapan metodologi dirancang secara terstruktur mulai dari pengumpulan data hingga evaluasi, sebagaimana divisualisasikan pada Gambar 1.



Gambar 1. Alur Program

Berdasarkan Gambar 1, alur penelitian dimulai dari tahap pengumpulan data yang bersumber dari *dataset* publik Kaggle serta pengumpulan mandiri. Data yang terkumpul kemudian memasuki tahap *preprocessing* menggunakan platform Roboflow, yang mencakup dua proses utama: (1) Augmentasi data seperti rotasi, flipping, dan cropping, serta (2) Pelabelan data (labelling) ke dalam tujuh kelas penyakit. Setelah data disiapkan, tahap berikutnya adalah pelatihan model menggunakan arsitektur Ultralytics YOLOv8 Nano dengan dua tahap pelatihan, yakni 30 *epoch* dan 100 *epoch*. Terakhir, model dievaluasi kinerjanya menggunakan metrik mAP, Confusion Matrix, dan F1 Score sebelum penelitian dinyatakan selesai.

2.1 Pengumpulan *DataSet*

Dataset dalam penelitian ini bersumber dari dua lokasi, yaitu platform Kaggle dan pengumpulan mandiri. *Dataset* mandiri diperoleh melalui proses pengambilan foto langsung pada tanaman tomat oleh peneliti, sedangkan *dataset* Kaggle diakses melalui repositori publik. Total keseluruhan *dataset* yang digunakan dalam penelitian ini berjumlah 737 sampel gambar. *Dataset* dalam penelitian ini bersumber dari dua lokasi, yaitu platform Kaggle dan pengumpulan mandiri. *Dataset* mandiri diperoleh melalui proses pengambilan foto langsung pada tanaman tomat oleh peneliti, sedangkan *dataset* Kaggle diakses melalui repositori publik. Total keseluruhan *dataset* yang digunakan dalam penelitian ini berjumlah 737 sampel gambar, Tabel 1 merupakan sumber *dataset* penelitian.

Tabel 1. Sumber *Dataset* Penelitian

No	Nama <i>Dataset</i>	Sumber / Kreator	Sifat Akses
1	Tomato Leaf Diseases Detection Computer Vision	Kaggle	Publik
2	Citra Daun Tomat Mandiri	Peneliti	Mandiri / Tertutup

2.2 *Preprocessing* Data

Preprocessing data dilaksanakan menggunakan platform Roboflow dengan menerapkan tiga teknik augmentasi untuk meningkatkan kualitas *dataset* [12]. Teknik rotasi gambar diterapkan dengan sudut rotasi -30° hingga $+30^{\circ}$, *horizontal* dan *vertical flipping* dengan probabilitas 0.5, serta *random cropping* dengan faktor skala 0.8-1.0 untuk mempertahankan fitur penting objek [13]. Proses augmentasi ini menghasilkan *dataset* yang baik buat pelatihan model selanjutnya. *Dataset* kemudian dilabeli ke dalam tujuh kelas klasifikasi penyakit daun tomat: bacterial spot, early blight, healthy, late blight, leaf mold, target spot, dan black spot. Distribusi *dataset* diatur dengan proporsi yang dapat dilihat pada Tabel 2

Tabel 2. Distribusi *DataSet*

No	<i>Train</i> (87.5%)	<i>Valid</i> (8.3%)	<i>Test</i> (4.2%)
1	645	61	31
Total	737 sampel		

2.3 Pelatihan Model

Model yang digunakan adalah YOLOv8 Nano, yang dirancang untuk efisiensi tinggi pada perangkat dengan sumber daya terbatas, YOLOv8 Nano adalah versi ringan dari YOLOv8 yang menawarkan keseimbangan antara akurasi dan kecepatan di dalam keterbatasan sumber daya [14].

Proses pelatihan YOLOv8 Nano dilakukan melalui dua tahap utama untuk memastikan model dapat mempelajari pola data secara optimal dan meningkatkan akurasi deteksinya [15]. Tahapan ini dirancang agar model dapat memanfaatkan keunggulan transfer learning sekaligus melakukan penyesuaian pada *dataset* spesifik yang digunakan. Pada tahapan pertama, pelatihan model awal dilakukan sebanyak 30 *epoch* dengan *batch size* sebesar 16. Selanjutnya, proses kedua dilanjutkan secara *fine-tuning* hingga mencapai 100 *epoch* dengan *batch size* sebesar 16 untuk menstabilkan bobot jaringan (weights).

2.4 Evaluasi Kinerja

Setelah proses pelatihan selesai, kinerja model dievaluasi untuk memastikan kemampuannya dalam mendeteksi objek dengan akurasi yang tinggi. Evaluasi dilakukan

menggunakan tiga metrik utama, yaitu Mean Average Precision (mAP), Confusion Matrix, dan F1 Score [16], yang dimana Mean Average Precision (mAP) biasanya digunakan dalam tugas *object detection* untuk mengevaluasi kemampuan model mendeteksi objek dalam gambar. mAP dihitung dengan langkah-langkah berikut: pertama, hitung Precision dan Recall untuk setiap kelas pada berbagai ambang batas (threshold), lalu buat kurva Precision-Recall (PR curve) untuk setiap kelas. Selanjutnya, hitung Average Precision (AP) sebagai luas area di bawah kurva PR, dan akhirnya rata-rata AP dari semua kelas dihitung menggunakan Rumus average precision (mAP) pada rumus 1 [17] :

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

Keterangan : n adalah total jumlah kelas klasifikasi, dan AP_i adalah nilai presisi rata-rata pada kelas ke-i.

Sedangkan *confusion matrix* adalah matriks yang menunjukkan performa model klasifikasi berdasarkan hasil prediksi dan label sebenarnya . Dalam matriks ini, terdapat empat elemen dasar, yaitu:

- TP (True Positive): Jumlah data yang diprediksi benar masuk ke dalam kelas positif (sesuai penyakitnya).
- FP (False Positive): Jumlah data yang salah diprediksi sebagai kelas positif, padahal aslinya negatif.
- TN (True Negative): Jumlah data yang diprediksi benar masuk ke dalam kelas negatif (contoh: diprediksi sehat dan aslinya memang sehat).
- FN (False Negative): Jumlah data positif yang gagal dideteksi oleh model (diprediksi negatif, padahal aslinya positif) [18] ;

Pehitungan *confusion matrix* dapat di tulis pada Rumus 2.

$$\begin{aligned} \text{Precision} &= \frac{TP}{TP+FP}, \\ \text{Recall} &= \left(\frac{TP}{TP+FN} \right), \\ \text{Akurasi} &= \frac{TP+TN}{TP+TN+FP+FN} \end{aligned} \quad (2)$$


Precision mengukur rasio ketepatan prediksi positif yang dihasilkan oleh model dibandingkan dengan keseluruhan hasil prediksi positif. Metrik ini digunakan untuk melihat seberapa akurat tebakan model. Recall mengukur seberapa baik model dalam mengenali dan menemukan kembali seluruh data positif yang sebenarnya. Akurasi mengukur persentase keseluruhan prediksi yang benar (baik TP maupun TN) terhadap total keseluruhan data yang diuji. *F1 Score* adalah rata-rata harmonis antara Precision dan Recall, yang sangat berguna untuk data tidak seimbang karena mampu menyeimbangkan trade-off antara keduanya, atau bisa ditulis dengan Rumus 3 [19] :

$$F1 \text{ Score} = 2 \times \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad \text{Atau} \quad \frac{2 \times TP}{2 \times TP + FP + FN} \quad (3)$$

Secara umum, mAP digunakan dalam evaluasi deteksi objek, *Confusion Matrix* untuk analisis model klasifikasi (termasuk *multiclass*), dan F1 Score untuk mengoptimalkan performa pada data yang tidak seimbang [20].


3. Hasil dan Pembahasan

Setelah melalui tahapan pelatihan model, proses pelatihan dilakukan dalam dua tahap. Tahap pertama terdiri dari 30 *epoch*, kemudian dilanjutkan dengan tahap kedua sebanyak 100 *epoch* menggunakan model YOLOv8 Nano sebagai model pelatihan. Dari keseluruhan proses tersebut, diperoleh pada *Gambar 2*:



Gambar 2. Evaluasi Kinerja Model


Hasil penelitian ini menunjukkan bahwa model yang digunakan memiliki performa yang menjanjikan berdasarkan metrik loss dan evaluasi yang terpantau selama proses pelatihan dan validasi (Gambar2). Grafik train/box_loss, train/cls_loss, dan train/df_l_loss menunjukkan penurunan konsisten seiring bertambahnya *epoch*, mencerminkan kemampuan model untuk belajar secara efektif dari data pelatihan. Pada akhir pelatihan, box_loss mendekati nilai 0.8, sementara cls_loss dan df_l_loss turun hingga di bawah 1, menandakan perbaikan yang signifikan. Grafik validasi, seperti yang terlihat pada val/box_loss, val/cls_loss, dan val/df_l_loss, juga menunjukkan pola penurunan yang serupa. Namun, penurunan tersebut lebih fluktuatif dibandingkan dengan grafik pelatihan, dengan nilai box_loss dan cls_loss masing-masing mencapai sekitar 1.2 dan di bawah 2. Fluktuasi ini menandakan adanya variabilitas pada data validasi, yang umum terjadi pada model *deep learning*. Dari segi metrik evaluasi, seperti yang ditunjukkan oleh metrics/precision(B) dan metrics/recall(B), terjadi peningkatan bertahap hingga stabil setelah sekitar *epoch* ke-50. Metrik mAP50 (Mean Average Precision pada IoU 50%) dan mAP50-95 menunjukkan performa deteksi yang membaik secara bertahap. mAP50 mencapai sekitar 0.8, sementara mAP50-95, yang lebih menantang, mencapai sekitar 0.5 pada akhir pelatihan.



Gambar 3. Grafik Confusion Matrix Evaluasi Kinerja Model

Dari grafik Confusion Matrix pada Gambar 3 model menunjukkan kemampuan yang baik dalam mengenali beberapa kelas, dengan "Early_Blight" sebagai kelas dengan prediksi benar tertinggi, yaitu 83 sampel yang terklasifikasi dengan benar, menandakan pengenalan yang sangat baik pada kelas ini. "Bacterial Spot" juga memiliki performa cukup baik, meskipun terdapat beberapa prediksi salah ke kelas "Early_Blight" dan "Healthy," yang menunjukkan masih ada ruang untuk meningkatkan akurasi. Kelas "Healthy" tampil cukup konsisten, dengan sebagian

besar sampel terklasifikasi dengan benar, meskipun ada kesalahan minor seperti terklasifikasi sebagai "Late_blight" atau "Leaf Mold," yang dapat diperbaiki melalui pelatihan lebih lanjut. Sementara itu, kelas "Black Spot" menunjukkan tantangan dalam prediksi, tetapi tetap memberikan wawasan positif mengenai perlunya pemisahan fitur yang lebih baik untuk kelas ini. Secara keseluruhan, distribusi prediksi yang tersebar menunjukkan bahwa model telah mengenali pola dengan baik.



Gambar 4. F1 Curve Evaluasi Kinerja Model

Grafik pada Gambar 4 nilai F1 maksimum tercapai pada *confidence* sekitar 0,506 untuk semua kelas secara keseluruhan, dengan rata-rata F1 sebesar 0,72, yang menunjukkan model mencapai keseimbangan yang sangat baik antara presisi dan recall pada tingkat kepercayaan tersebut. Kelas "Healthy" menunjukkan performa yang sangat baik dengan nilai F1 tinggi di hampir seluruh tingkat *confidence*, menandakan bahwa model sangat efektif dalam membedakan kelas ini dari kelas lainnya. Sementara itu, "Bacterial Spot," "Early Blight," dan "Target Spot" menunjukkan fluktuasi nilai F1 yang cukup variatif, yang memberikan indikasi bahwa model masih terus belajar untuk mengklasifikasikan kelas-kelas ini dengan lebih konsisten. Adapun "Leaf Mold" dan "Black Spot" menunjukkan peluang untuk lebih ditingkatkan dengan pendekatan yang lebih tepat, agar model dapat lebih mudah membedakan kedua kelas tersebut dengan akurasi yang lebih tinggi. Selain melalui pengukuran menggunakan tiga grafik, visualisasi hasil pelatihan juga dilakukan untuk memberikan gambaran yang lebih jelas dan intuitif mengenai kinerja model. Visualisasi ini membantu memahami bagaimana model mendeteksi objek pada daun tomat. Berikut adalah beberapa contoh hasil uji coba model menggunakan beberapa gambar daun tomat sebagai sampel.



Gambar 5. Uji Coba Sample Foto Pada Kinerja Model

Pencapaian tersebut memperkuat bukti bahwa model klasifikasi berbasis *machine learning* memiliki potensi besar dalam mendeteksi penyakit tanaman secara akurat, seperti yang terlihat dari performa pada kurva *F1-Confidence* dan *confusion matrix*. Model ini menunjukkan keseimbangan optimal antara presisi dan recall pada tingkat kepercayaan tertentu (*confidence* 0.506), yang membuatnya cocok untuk aplikasi keberlanjutan seperti sistem monitoring kesehatan tanaman secara otomatis atau platform berbasis IoT (*Internet of Things*).

Namun, tantangan utama yang masih perlu diperhatikan adalah performa yang bervariasi pada beberapa kelas. Fluktuasi nilai F1-Score pada kelas seperti Bacterial Spot dan Black spot menunjukkan bahwa model belum sepenuhnya stabil dalam mendeteksi penyakit tertentu, yang kemungkinan disebabkan oleh tumpang tindih fitur antar kelas atau ketidakseimbangan *dataset*. Menurut [21] Augmentasi data tambahan dengan memperluas variasi gambar, seperti perubahan pencahayaan, rotasi ekstrim, dan penambahan noise, dapat membantu meningkatkan generalisasi model untuk mengatasi permasalahan ini.

Penelitian ini membuka peluang untuk pengembangan lebih lanjut, seperti integrasi model dengan perangkat drone atau platform berbasis sensor di lapangan. Pengembangan model *ensemble* dengan menggabungkan arsitektur *machine learning* lainnya juga dapat menjadi solusi untuk meningkatkan sensitivitas terhadap penyakit dengan pola-pola yang lebih kompleks. Dengan demikian, penelitian ini tidak hanya memberikan kontribusi signifikan pada bidang deteksi penyakit tanaman, tetapi juga menjadi dasar penting bagi pengembangan teknologi pertanian meningkat.

4. Kesimpulan

Penelitian ini telah berhasil mengembangkan model klasifikasi penyakit pada daun tomat menggunakan analisis *machine learning* berbasis kurva F1 dan *confusion matrix*. Sistem ini menunjukkan nilai rata-rata F1 sebesar 0.72 pada tingkat *confidence* 0.506, dengan performa tinggi pada kelas "Healthy," meskipun beberapa kelas seperti "Bacterial Spot" dan "Black spot" masih menunjukkan tingkat kesalahan yang signifikan. Analisis *confusion matrix* mengindikasikan bahwa model lebih efektif dalam mengenali pola pada kelas dengan karakteristik fitur yang unik dibandingkan dengan kelas yang memiliki tumpang tindih fitur.

Upaya seperti *balancing dataset*, augmentasi data, dan penambahan fitur yang lebih representatif memainkan peran penting dalam meningkatkan performa model. Namun, tantangan seperti ketidakseimbangan data dan kompleksitas pola antar kelas masih membutuhkan perhatian lebih lanjut. Penelitian ini menunjukkan potensi besar penerapan *machine learning* dalam sistem monitoring tanaman tomat untuk mendeteksi penyakit daun secara lebih akurat dan efisien.

Untuk meningkatkan generalisasi dan akurasi model, pengujian dengan *dataset* yang lebih besar dan lebih beragam, serta penerapan teknik *fine-tuning*, sangat diperlukan. Hasil penelitian ini juga membuka peluang untuk pengembangan lebih lanjut, seperti integrasi dengan perangkat IoT atau pengembangan lainnya.

Daftar Pustaka

- [1] M. Z. Abidin, "Pemulihan ekonomi nasional pada masa pandemi covid-19: Analisis produktivitas tenaga kerja sektor pertanian," *Indones. Treas. Rev. J. Perbendaharaan, Keuang. Negara Dan Kebijak. Publik*, vol. 6, no. 2, pp. 117–138, 2021.
- [2] C. Hou *et al.*, "Recognition of early blight and late blight diseases on potato leaves based on graph cut segmentation," *J. Agric. Food Res.*, vol. 5, p. 100154, 2021.
- [3] A. M. Lesmana, R. P. Fadhillah, and C. Rozikin, "Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN)," *J. Sains dan Inform. p-*

ISSN, vol. 2460, p. 173X, 2022.

- [4] V. Singh, N. Sharma, and S. Singh, "A review of imaging techniques for plant disease detection," *Artif. Intell. Agric.*, vol. 4, pp. 229–242, 2020.
- [5] A. Seba, N. Nouali-Taboudjemat, N. Badache, and H. Seba, "A review on security challenges of wireless communications in disaster emergency response and crisis management situations," *J. Netw. Comput. Appl.*, vol. 126, pp. 150–161, 2019.
- [6] A. Tholib and M. Kom, "Implementasi Algoritma Machine Learning Berbasis Web dengan Framework Streamlit," *Pustaka Nurja*, 2023.
- [7] J. Lu, L. Tan, and H. Jiang, "Review on convolutional neural network (CNN) applied to plant leaf disease classification," *Agriculture*, vol. 11, no. 8, p. 707, 2021.
- [8] Y. Toda and F. Okura, "How convolutional neural networks diagnose plant disease," *Plant Phenomics*, 2019.
- [9] H. Wang, S. Shang, D. Wang, X. He, K. Feng, and H. Zhu, "Plant disease detection and classification method based on the optimized lightweight YOLOv5 model," *Agriculture*, vol. 12, no. 7, p. 931, 2022.
- [10] N. Chitrangirum *et al.*, "Comparison study of corn leaf disease detection based on deep learning YOLO-v5 and YOLO-v8," *J. Eng. Technol. Sci.*, vol. 56, no. 1, pp. 61–70, 2024.
- [11] P. Kumar and U. Misra, "Deep Learning for Weed Detection: Exploring YOLO V8 Algorithm's Performance in Agricultural Environments," in *2024 2nd International Conference on Disruptive Technologies (ICDT)*, IEEE, 2024, pp. 255–258.
- [12] S. G. E. Brucal, L. C. M. de Jesus, S. R. Peruda, L. A. Samaniego, and E. D. Yong, "Development of Tomato Leaf Disease Detection using YoloV8 Model via RoboFlow 2.0," in *2023 IEEE 12th Global Conference on Consumer Electronics (GCCE)*, IEEE, 2023, pp. 692–694.
- [13] R. S. Latha *et al.*, "Fruits and vegetables recognition using YOLO," in *2022 International Conference on Computer Communication and Informatics (ICCCI)*, IEEE, 2022, pp. 1–6.
- [14] Z. Wang, Z. Hua, Y. Wen, S. Zhang, X. Xu, and H. Song, "E-YOLO: Recognition of estrus cow based on improved YOLOv8n model," *Expert Syst. Appl.*, vol. 238, p. 122212, 2024.
- [15] Y. Tian, D. Zhao, and T. Wang, "An improved YOLO Nano model for dorsal hand vein detection system," *Med. Biol. Eng. Comput.*, vol. 60, no. 5, pp. 1225–1237, 2022.
- [16] A. E. Maxwell, T. A. Warner, and L. A. Guillén, "Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—Part 1: Literature review," *Remote Sens.*, vol. 13, no. 13, p. 2450, 2021.
- [17] A. Ahmad, D. Saraswat, V. Aggarwal, A. Etienne, and B. Hancock, "Performance of deep learning models for classifying and detecting common weeds in corn and soybean production systems," *Comput. Electron. Agric.*, vol. 184, p. 106081, 2021.
- [18] I. Markoulidakis, G. Kopsiaftis, I. Rallis, and I. Georgoulas, "Multi-class confusion matrix reduction method and its application on net promoter score classification problem," in *Proceedings of the 14th Pervasive Technologies Related to Assistive Environments Conference*, 2021, pp. 412–419.
- [19] R. G. Goriparthi, "AI-Driven Natural Language Processing for Multilingual Text Summarization and Translation," *Rev. Intel. Artif. en Med.*, vol. 12, no. 1, pp. 513–535, 2021.
- [20] A. Meliboev, J. Alikhanov, and W. Kim, "Performance evaluation of deep learning based network intrusion detection system across multiple balanced and imbalanced datasets," *Electronics*, vol. 11, no. 4, p. 515, 2022.
- [21] E. Gocer, "Medical image data augmentation: techniques, comparisons and interpretations," *Artif. Intell. Rev.*, vol. 56, no. 11, pp. 12561–12605, 2023.