



## Sistem Deteksi Penyakit Pada Tanaman Cabai Menggunakan RT-DETR dan YOLO V8

Pedro Lucio Parera<sup>1\*</sup>, Gregorius Bayu Listyoputro<sup>2</sup>, Krisnavaro Raihananta<sup>3</sup>, Rachmat Adi purnama<sup>4</sup>, Rame Santoso<sup>5</sup>, Veti Apriana<sup>6</sup>

<sup>1-4</sup> Program Studi Informatika, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika, Indonesia

<sup>5</sup> Program Studi Sistem Informasi, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika, Indonesia

<sup>6</sup> Program Studi Teknik industri, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika, Indonesia

Email: [pedroparera40@gmail.com](mailto:pedroparera40@gmail.com)<sup>1</sup>, [gregoriusbayu46@gmail.com](mailto:gregoriusbayu46@gmail.com)<sup>2</sup>, [krisnavaro312@gmail.com](mailto:krisnavaro312@gmail.com)<sup>3</sup>, [rachmat.rap@bsi.ac.id](mailto:rachmat.rap@bsi.ac.id)<sup>4</sup>, [rame.rms@bsi.ac.id](mailto:rame.rms@bsi.ac.id)<sup>5</sup>, [veti.vta@bsi.ac.id](mailto:veti.vta@bsi.ac.id)<sup>6</sup>

\*Penulis Korespondensi: [pedroparera40@gmail.com](mailto:pedroparera40@gmail.com)

**Abstrack:** *This study investigates the performance of two state-of-the-art object detection models, YOLOv8 and RT-DETR, in identifying diseases in chili plants, which represent a major challenge affecting horticultural productivity. Diseases such as anthracnose and Cercospora leaf spot often cause significant yield losses, and traditional manual identification tends to be inefficient, subjective, and error-prone due to the visual similarities found among disease symptoms. The objective of this research is to evaluate and compare the capabilities of both models using the Chili dataset from Roboflow Universe consisting of four classes: Anthracnose, Cercospora Leaf Spot, Healthy Fruit, and Healthy Leaf. The methodology includes data preprocessing, training using identical hyperparameters, and performance evaluation through accuracy and model behavior analysis during real-world testing. The findings indicate that RT-DETR achieves higher accuracy in controlled testing, reaching 90% for Anthracnose, 95% for Healthy Leaf, 100% for Healthy Fruit, and 85% for Cercospora Leaf Spot, supported by its transformer-based architecture that enhances spatial understanding. However, YOLOv8 demonstrates superior stability and consistency in real-world scenarios involving varying lighting, leaf orientations, and natural texture variations. The model also produces fewer misclassification errors, making it more reliable for practical field deployment. The implications of these results show that YOLOv8 is the most suitable model for integration into a Streamlit-based application due to its fast, responsive, and accurate inference, supporting early disease detection for chili farmers.*

**Keywords:** *Chili Disease Detection; Deep Learning; RT-DETR; Streamlit; YOLOv8*

**Abstrak:** Penelitian ini mengkaji performa dua model deteksi objek modern, yaitu YOLOv8 dan RT-DETR, dalam mengidentifikasi penyakit pada tanaman cabai yang menjadi salah satu faktor utama penurunan produktivitas hortikultura. Penyakit seperti Antraknosa dan Bercak Cercospora sering menyebabkan kerugian hasil panen yang signifikan, sementara proses identifikasi manual cenderung kurang efisien, subjektif, dan rawan kesalahan karena adanya kemiripan visual antar gejala penyakit. Tujuan penelitian ini adalah mengevaluasi dan membandingkan kemampuan kedua model tersebut menggunakan dataset Cabai dari Roboflow Universe yang terdiri dari empat kelas: Antraknosa, Bercak Cercospora, Buah Sehat, dan Daun Sehat. Metode yang digunakan meliputi preprocessing data, pelatihan model dengan parameter yang serupa, serta evaluasi performa berdasarkan akurasi dan perilaku model pada pengujian di lapangan. Hasil penelitian menunjukkan bahwa RT-DETR menghasilkan akurasi lebih tinggi pada pengujian terkontrol, yaitu 90% untuk Antraknosa, 95% untuk Daun Sehat, 100% untuk Buah Sehat, dan 85% untuk Bercak Cercospora, berkat arsitektur transformer yang mampu memahami hubungan spasial secara lebih mendalam. Namun, YOLOv8 menunjukkan stabilitas dan konsistensi yang lebih baik pada kondisi nyata dengan variasi pencahayaan, orientasi daun, dan tekstur alami tanaman. Model ini juga menghasilkan kesalahan klasifikasi yang lebih rendah sehingga lebih andal untuk implementasi praktis. Implikasi temuan ini menunjukkan bahwa YOLOv8 merupakan model yang paling tepat untuk diintegrasikan dalam aplikasi berbasis Streamlit karena mampu memberikan inferensi yang cepat, responsif, dan akurat guna mendukung deteksi dini penyakit pada tanaman cabai.

**Kata kunci:** Cabai; Deep Learning; Deteksi Penyakit; RT-DETR; YOLOv8

## 1. LATAR BELAKANG

Tanaman cabai merupakan salah satu komoditas hortikultura bernilai ekonomi tinggi di Indonesia. Permintaan cabai yang terus meningkat, baik untuk konsumsi rumah tangga maupun industri pengolahan, menjadikan stabilitas produksinya sangat penting. Namun demikian, produktivitas cabai sering mengalami penurunan akibat serangan penyakit pada daun dan buah. Dua penyakit utama yang sering ditemukan pada pertanaman cabai adalah Antraknosa dan Bercak Cercospora, selain kondisi buah sehat dan daun sehat sebagai pembanding penting dalam proses identifikasi.

Antraknosa disebabkan oleh jamur *Colletotrichum* spp. yang menimbulkan lesi cekung berwarna gelap pada buah cabai dan berpotensi menyebabkan kerugian pada fase budidaya maupun pascapanen. Sementara itu, Bercak Cercospora disebabkan oleh *Cercospora capsici* yang menyerang daun dengan gejala awal berupa bercak kecil yang terus melebar sehingga mengganggu proses fotosintesis tanaman. Deteksi dini penyakit ini sangat penting karena tingkat keparahan serangan dapat menyebabkan penurunan hasil panen secara signifikan. Penelitian terbaru telah menunjukkan bahwa metode berbasis deep learning mampu mendeteksi penyakit *Cercospora* pada cabai dengan akurasi tinggi, bahkan pada kondisi lapang yang beragam (Leite et al., 2025).

Selama ini proses identifikasi penyakit cabai masih dilakukan secara manual oleh petani dan penyuluh lapang. Pendekatan tradisional ini membutuhkan pengalaman ahli, rentan terhadap subjektivitas, serta kurang efisien ketika gejala penyakit memiliki kemiripan visual. Sejumlah penelitian menunjukkan bahwa teknologi computer vision menawarkan solusi yang lebih cepat, presisi, dan konsisten dalam diagnosis penyakit tanaman (Ghafar et al., 2024; Lye et al., 2023).

Kemajuan deep learning, khususnya melalui model deteksi objek modern seperti YOLOv8 dan arsitektur transformer seperti RT-DETR, membuka peluang besar dalam otomatisasi deteksi penyakit tanaman. YOLOv8 terbukti efektif dalam pendeteksian penyakit tanaman berkat pendekatan anchor-free dan efisiensi komputasinya (Ghafar et al., 2024). Di sisi lain, arsitektur transformer telah menunjukkan kinerja unggul dalam klasifikasi dan deteksi penyakit tanaman, bahkan pada kondisi citra yang bervariasi (Aboelenin et al., 2025; Barman et al., 2024).

Dalam penelitian ini, digunakan dataset publik dari Roboflow Universe yaitu dataset *Cabai* (<https://universe.roboflow.com/laitsa-nailil-azkia/cabai-mwz0j/dataset/31>), yang berisi empat kelas anotasi: Antraknosa, Bercak Cercospora, Buah Sehat, dan Daun Sehat. Dataset ini menyediakan variasi citra dengan kondisi pencahayaan, posisi objek, dan tingkat keparahan

penyakit yang berbeda, sehingga sangat mendukung pelatihan dan evaluasi model deteksi objek berbasis deep learning.

Dengan memanfaatkan dataset tersebut, implementasi model YOLOv8 dan RT-DETR diharapkan mampu menghasilkan sistem deteksi penyakit tanaman cabai yang lebih akurat dan cepat. Sistem ini berpotensi membantu petani dalam melakukan diagnosis dini, mengurangi potensi kerugian hasil panen, serta meningkatkan efisiensi dalam praktik pertanian modern.

## 2. KAJIAN TEORITIS

### Studi Terkait

**Table 1.** Penelitian Terkait.

Sitasi	Tahun	Judul	Metodologi	Kesimpulan
(Huang et al., 2023)	2023	YOLOv8-Based Plant Leaf Disease Detection	Pelatihan YOLOv8 pada dataset penyakit daun tanaman (cabai, tomat, kentang). Menggunakan 100 epoch, ukuran gambar 640×640, optimizer AdamW. Evaluasi menggunakan mAP50 dan mAP50-95.	YOLOv8 menunjukkan peningkatan akurasi 4–6% dibanding YOLOv5. Kecepatan inferensi sangat tinggi sehingga cocok untuk implementasi real-time.
(Uzair et al., 2024)	2024	Real-Time Detection of Plant Diseases Using YOLOv8	Melatih YOLOv8 pada dataset multi-class penyakit daun hortikultura. Augmentasi menggunakan mosaic, flipping, CLAHE, dan HSV shift.	YOLOv8 menghasilkan mAP50 96%. Stabil pada kondisi cahaya tidak seragam. Direkomendasikan untuk smart farming.
(Wang et al., 2023)	2023	RT-DETR: Real-Time Detection Transformer	Perancangan arsitektur transformer real-time tanpa NMS. Dilatih pada dataset COCO, diuji untuk kasus real-time detection. Evaluasi mAP dan FPS.	RT-DETR mencapai kecepatan tinggi (30–40 FPS) dengan akurasi mendekati DETR. Efektif untuk sistem deteksi objek real-time seperti deteksi penyakit tanaman.

(Khan et al., 2024)	2024	Comparative Study of YOLOv8 and RT-DETR for Agricultural Disease Detection	Membandingkan YOLOv8 dan RT-DETR pada dataset penyakit tanaman ( $\pm 4.200$ gambar). Metodologi: training 150 epoch, batch 16, imgsz 512, eval menggunakan mAP50-95.	YOLOv8 lebih cepat saat inference di edge-device, sedangkan RT-DETR lebih stabil dan akurat untuk objek berukuran kecil.
(Roboflow, 2024)	2024	Chili Plant Disease Dataset v31	Dataset publik berisi empat kelas: Antraknosa, Bercak Cercospora, Buah Sehat, dan Daun Sehat. Digunakan banyak penelitian YOLOv8 dan RT-DETR.	Dataset sangat bervariasi, cocok untuk pengujian deteksi objek berbasis deep learning.

Pada Tabel 1 menunjukkan beberapa penelitian sebelumnya tentang deteksi penyakit tanaman cabai, serta ringkasan dari penelitian tersebut.

### Machine Learning dan Deep Learning

Machine learning merupakan bidang kajian yang berfokus pada pengembangan dan analisis algoritma yang memungkinkan sistem komputer mampu belajar dari data. Dalam konteks ini, komputer dapat membangun model berdasarkan pola dalam data dan menggunakan model tersebut untuk melakukan prediksi atau pengambilan keputusan (Daqiqil, 2021).

Salah satu cabang machine learning yang berkembang pesat adalah deep learning, yang meniru cara kerja otak manusia melalui struktur jaringan neuron. Pendekatan ini mengandalkan jaringan saraf tiruan dengan banyak lapisan tersembunyi untuk mengekstraksi fitur secara bertahap. Berbagai arsitektur dalam deep learning antara lain Multilayer Perceptron (MLP), Autoencoder (AE), Convolutional Neural Networks (CNN), dan Recurrent Neural Networks (RNN). (Arya et al., 2021).

### YOLOv8 dan RT-DETR

You Only Look Once (YOLO) merupakan salah satu algoritma deteksi objek real-time yang bekerja dengan pendekatan *single-stage detector*. Pada YOLO, proses deteksi dilakukan menggunakan satu jaringan convolutional yang secara simultan memprediksi *bounding box*

serta probabilitas kelas dalam satu proses inferensi terpadu, sehingga menghasilkan kecepatan dan efisiensi yang tinggi (Fatkhin & Fadjeri, 2024).

YOLOv8 sebagai generasi terbaru dari keluarga YOLO menghadirkan berbagai peningkatan, baik dari sisi arsitektur maupun optimasi model. Dibangun sebagai penyempurnaan dari YOLOv7, YOLOv8 menawarkan akurasi yang lebih tinggi, efisiensi komputasi lebih baik, serta performa lebih stabil pada berbagai skenario deteksi objek (Iman et al., 2025).

Sementara itu, algoritma Real-Time Detection Transformer (DETR) memanfaatkan arsitektur transformer dengan mekanisme *self-attention* untuk melakukan deteksi objek tanpa memerlukan komponen seperti anchor box atau Non-Maximum Suppression (NMS). Pendekatan ini memungkinkan DETR memetakan hubungan spasial secara lebih efektif dan menghasilkan prediksi yang lebih stabil (Khoiriyah, 2023).

### **Computer Vision**

Visi komputer merupakan salah satu cabang kecerdasan buatan yang memungkinkan komputer mempelajari cara manusia melihat, memahami, serta menafsirkan objek atau pola visual. Teknologi ini dipakai untuk memproses dan menganalisis data visual sehingga sistem dapat mengambil tindakan berdasarkan informasi yang diekstraksi. Penerapan visi komputer dalam organisasi mampu memberikan berbagai manfaat, seperti penyederhanaan proses operasional, peningkatan efisiensi kinerja, perbaikan pengalaman pelanggan, serta penguatan daya saing bisnis. (Intel, 2025).

Kecerdasan buatan (AI) sendiri merupakan teknologi yang dirancang untuk meniru kemampuan kognitif manusia, termasuk penalaran logis, pemecahan masalah, dan pengambilan keputusan. Dalam dunia pendidikan, AI dapat dimanfaatkan sebagai asisten pembelajaran yang mampu memperkaya, mempersonalisasi, dan meningkatkan efektivitas proses belajar. (Damayanti & others, 2024).

### **Deteksi Objek**

Deteksi objek merupakan salah satu metode dalam bidang computer vision yang memungkinkan identifikasi dan pelacakan objek pada citra atau video. Metode ini biasanya memanfaatkan algoritma deep learning untuk mengenali pola dan fitur visual, sehingga menghasilkan prediksi yang lebih akurat dan andal (Aningtiyas & others, 2020).

### **Cabai**

Cabai (*Capsicum spp.*) adalah salah satu tanaman hortikultura yang memiliki nilai ekonomi tinggi dan banyak dibudidayakan di Indonesia. Tanaman ini termasuk dalam keluarga Solanaceae dan dikenal karena buahnya yang memiliki rasa pedas akibat kandungan senyawa

kapsaisin. Cabai memiliki peranan penting dalam pola konsumsi masyarakat, industri pengolahan makanan, serta perdagangan lokal dan internasional. Produktivitas cabai sangat dipengaruhi oleh kondisi lingkungan, teknik budidaya, serta serangan hama dan penyakit, sehingga pemeliharaan dan pemantauan kesehatan tanaman menjadi aspek penting dalam pertanian modern (Suryadi & Putra, 2022).

Cabai dibagi menjadi beberapa jenis berdasarkan ukuran, warna, dan tingkat kepedasan, antara lain cabai rawit, cabai besar, dan cabai keriting. Tanaman ini umumnya ditanam untuk buahnya yang digunakan sebagai bumbu, bahan olahan, dan komoditas perdagangan.

### **3. METODE PENELITIAN**

#### **Objek Penelitian**

Objek penelitian ini difokuskan kepada deteksi penyakit pada tanaman cabai. Tujuan utama dari penelitian ini adalah untuk merancang dan mengevaluasi kinerja model deep learning dalam mengklasifikasikan jenis penyakit tanaman cabai secara otomatis berdasarkan citra daun, serta untuk mengembangkan model deteksi penyakit yang akurat dan efisien sehingga dapat membantu petani dalam mengidentifikasi gejala penyakit pada tanaman cabai secara dini.




**Gambar 1.** Roboflow.

Dataset yang digunakan berasal dari platform Roboflow yang menyediakan kumpulan gambar berkualitas tinggi berkaitan dengan penyakit pada tanaman cabai yang menyediakan citra dengan anotasi detail terkait jenis penyakit, sehingga memungkinkan proses pelatihan, validasi, dan pengujian model dilakukan secara sistematis dan terukur.”

#### **Prosedur Penelitian**

Prosedur penelitian ini dirancang secara sistematis dan diorganisasikan ke dalam beberapa tahapan, yang divisualisasikan pada Gambar 2. Untuk memastikan keterulangan, validitas, dan transparansi penelitian, setiap tahapan mulai dari akuisisi data, preprocessing dataset, pelatihan model, pengujian model, evaluasi model, hingga implementasi akan dijelaskan secara rinci pada bagian berikut.



**Gambar 2.** Alur Penelitian.

### Akuisisi Data

Untuk keperluan pengumpulan data, sampel citra diperoleh dari platform Roboflow yang menyediakan dataset publik untuk berbagai kebutuhan penelitian berbasis pengolahan citra. Dataset yang digunakan dalam penelitian ini berjumlah 2.745 gambar yang dibagi ke dalam tiga subset, yaitu 2.252 gambar sebagai training set (82%), 327 gambar sebagai validation set (12%), dan 166 gambar sebagai test set (6%). Seluruh citra dikelompokkan ke dalam empat kelas penyakit tanaman cabai sesuai kategori yang telah ditetapkan. Struktur dataset mengikuti standar format YOLO yang disediakan oleh Roboflow, terdiri atas folder images yang berisi citra mentah dan folder labels yang memuat anotasi bounding box dalam format YOLO TXT. Struktur ini mendukung proses pelatihan dan evaluasi model YOLOv8 dan RT-DETR agar dapat dilakukan secara konsisten, terorganisir, dan sesuai kebutuhan penelitian.

### Preprocessing Data

Sebelum digunakan dalam proses pelatihan, seluruh citra pada dataset melalui tahap preprocessing untuk memastikan kualitas data seragam dan sesuai dengan standar input model deteksi objek. Tahapan preprocessing meliputi proses resize citra ke ukuran yang sesuai dengan arsitektur YOLOv8 dan RT-DETR, sehingga setiap gambar memiliki resolusi yang konsisten sebelum masuk ke proses deteksi. Normalisasi piksel juga diterapkan untuk menyesuaikan rentang nilai piksel agar proses pelatihan berlangsung lebih stabil dan memungkinkan model mencapai konvergensi secara lebih optimal.

Untuk meningkatkan keragaman data dan memperkuat kemampuan generalisasi model, beberapa teknik data augmentation diterapkan pada training set, seperti horizontal flip, rotation, dan penyesuaian brightness. Teknik augmentasi ini membantu model mengenali objek penyakit cabai dalam berbagai kondisi pencahayaan, orientasi, dan posisi. Seluruh proses preprocessing dan augmentasi dilakukan secara otomatis melalui pipeline Roboflow, sehingga data yang digunakan oleh YOLOv8 maupun RT-DETR telah terstandarisasi, konsisten, dan siap digunakan pada tahap pelatihan, validasi, dan pengujian.

### Perancangan Dan Pelatihan model

Selama proses pelatihan, kedua model memperlihatkan kebutuhan komputasi yang berbeda ketika dijalankan pada platform Google Colab dengan dukungan GPU NVIDIA T4. Model YOLOv8 menyelesaikan proses pelatihan dalam waktu sekitar 65 menit, yang

menunjukkan tingginya efisiensi komputasi berkat arsitektur one-stage yang relatif ringan dan telah dioptimalkan untuk kecepatan. Sebaliknya, model RT-DETR memerlukan waktu pelatihan sekitar 90 menit, disebabkan oleh arsitektur berbasis transformer yang lebih kompleks serta mekanisme deteksi end-to-end tanpa penerapan Non-Maximum Suppression (NMS). Perbedaan durasi pelatihan tersebut mencerminkan disparitas kompleksitas algoritmik kedua model, sekaligus memberikan dasar pertimbangan dalam pemilihan model deteksi objek yang sesuai berdasarkan kebutuhan efisiensi komputasi dan kedalaman analisis yang diharapkan dalam penelitian ini.

### Pengujian Model

Pada tahap evaluasi, model YOLOv8 dan RT-DETR dijalankan untuk menilai performa deteksi penyakit tanaman cabai berdasarkan citra daun, dengan membandingkan prediksi model terhadap label asli. Evaluasi dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score — metrik ini sangat umum digunakan dalam penelitian deteksi objek dan klasifikasi citra. (Derit Junio & Putra, 2025; Ikasari & others, 2024) Precision mengukur ketepatan model dalam memprediksi kelas yang benar, sementara recall mengukur sejauh mana model dapat menangkap semua objek target. F1-score merupakan metrik harmonik dari precision dan recall, memberikan gambaran keseimbangan antara keduanya, terutama pada distribusi kelas yang tidak merata. Nilai metrik dihitung secara otomatis setelah proses inferensi pada test set, sehingga memungkinkan perbandingan performa yang objektif antara YOLOv8 dan RT-DETR. (Baihaqi et al., 2021)

Perhitungan akurasi dilakukan dengan persamaan:

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Jumlah Seluruh Data}} \times 100\%$$

Dengan rumus ini, performa YOLOv8 dan RT-DETR dapat dinilai dari proporsi prediksi yang benar dari seluruh sampel test. Hasil evaluasi menjadi dasar utama dalam menganalisis efektivitas kedua model dalam mendeteksi penyakit tanaman cabai.

### Evaluasi Model

Confusion matrix merupakan alat evaluasi yang sangat penting dalam menilai kinerja model deteksi atau klasifikasi, termasuk pada penelitian ini yang membandingkan performa YOLOv8 dan RT-DETR dalam mendeteksi empat kelas penyakit dan kondisi tanaman cabai, yaitu Antraknosa, Bercak Cercospora, Buah Sehat, dan Daun Sehat. Confusion matrix memberikan gambaran rinci mengenai jumlah prediksi benar dan salah pada setiap kelas, sehingga memudahkan peneliti dalam menganalisis tingkat akurasi model



serta pola kesalahan yang muncul selama proses inferensi. Melalui confusion matrix, dapat diamati kecenderungan model dalam menghasilkan false positive maupun false negative pada setiap kategori, yang menjadi indikator penting untuk memahami bagaimana masing-masing arsitektur mendeteksi objek daun dan buah cabai yang terinfeksi. Dengan demikian, confusion matrix berperan sebagai instrumen evaluasi yang esensial untuk menilai kemampuan YOLOv8 dan RT-DETR dalam mengenali kelas penyakit maupun kondisi sehat secara tepat, konsisten, serta membantu mengidentifikasi kelemahan model pada kelas tertentu yang mungkin memerlukan perbaikan atau penyesuaian lebih lanjut.

### **Implementasi**

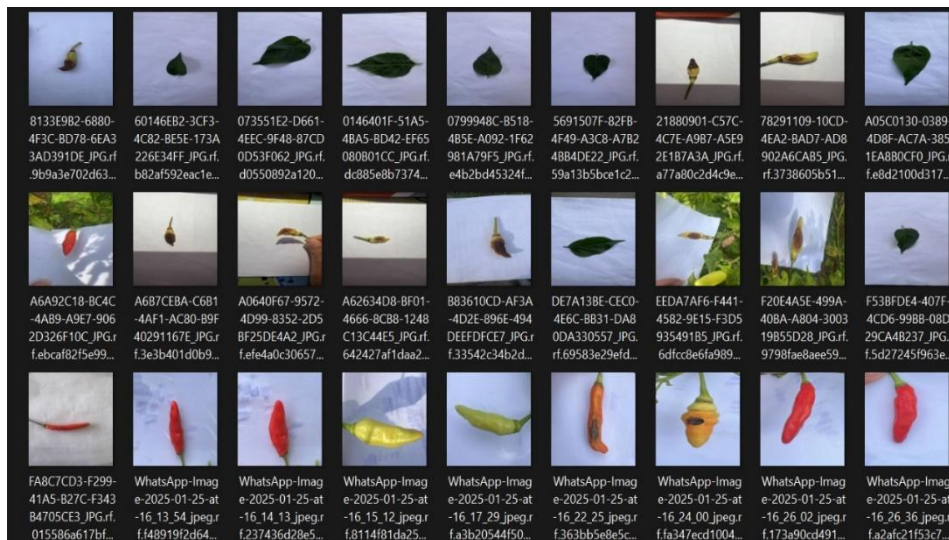
Setelah mendapatkan algoritma mana yang terbaik dalam akurasi dan kecepatannya lalu dilakukan implementasi sistem, dengan mengintegrasikan model ke dalam aplikasi berbasis web menggunakan Streamlit.

Sistem ini memungkinkan pengguna mengunggah citra uji, menjalankan proses deteksi secara *image*. Setelah mengunggah citra uji hasilnya bisa di *download* dan akan kesimpan ke folder *downloads* di komputer maupun handphone.

## **4. HASIL DAN PEMBAHASAN**

### **Akuisi Data**

Pada tahap awal penelitian, proses akuisi citra dilakukan untuk memperoleh data visual berupa gambar yang akan digunakan sebagai input dalam sistem deteksi penyakit pada tanaman cabai. Dataset diperoleh dari dataset publik yang tersedia pada platform roboflow berikut linknya, <https://universe.roboflow.com/laitsa-nailil-azkia/cabai-mwz0j/dataset/31> . Dataset ini terdiri dari 3 kelas,yakni Train Set yang terdiri dari 2252 gambar82%, Valid Set yang terdiri dari 327 gambar 12%, Test Set yang berisi 166 gambar6%.



Gambar 3. Dataset YOLOv8 dan RT-DETR.

### Preprocessing Data

Tahap **preprocessing** pada dataset dilakukan untuk memastikan setiap citra berada dalam kondisi optimal sebelum digunakan pada model **Yollo V8** dan **MobileNetV2**. Seluruh gambar diseragamkan menjadi **224 × 224 piksel**, yaitu ukuran input standar pada arsitektur **RT-DETR** dan **YOLOv8**, dan ukuran ideal untuk CNN Custom agar proses ekstraksi fitur berjalan stabil. Penyeragaman ini penting untuk menghindari ketidakkonsistenan dimensi yang dapat memengaruhi performa model selama pelatihan.

Proses augmentasi dan normalisasi dilakukan melalui Roboflow, mencakup rotasi, flipping, *brightness adjustment*, *zooming*, dan perubahan skala. Augmentasi tersebut bertujuan menambah variasi dataset sehingga model dapat belajar dari berbagai kondisi pencahayaan, orientasi daun, serta jarak pengambilan gambar. Normalisasi dilakukan untuk menyeimbangkan rentang intensitas piksel sehingga proses pelatihan menjadi lebih stabil dan cepat konvergen. Dengan rangkaian preprocessing ini, dataset menjadi lebih bervariasi, representatif, dan siap digunakan secara optimal oleh model CNN Custom maupun MobileNetV2.

### Pelatihan Model

Proses pelatihan model dimulai dengan pembagian dataset yang telah dilakukan melalui proses augmentasi menjadi tiga subset: test, train, dan val. Data yang digunakan terdiri dari 166 gambar untuk test set, 2252 gambar untuk train set, dan 327 gambar untuk valid set.

```

# Jalankan training
model.train(
    data="/content/drive/MyDrive/Colab Notebooks/Deteksi Penyakit Tanaman",
    epochs=30,
    imgsz=640,
    batch=12,
    optimizer="AdamW",
    lr=0.0015,
    patience=30,
    project=f"/content/drive/MyDrive/Colab Notebooks/{project_name}",
    name=model_name.split('.')[0],
    device=0,
    resume_resume_flag,
    plots=True,
    save=True
)
return model

```

Gambar 4. YOLLO V8.

```

# Jalankan training
model.train(
    data="/content/drive/MyDrive/Colab Notebooks/Deteksi Penyakit Tanaman",
    epochs=30,
    imgsz=640,
    batch=12,
    optimizer="AdamW",
    lr=0.0015,
    patience=30,
    project=f"/content/drive/MyDrive/Colab Notebooks/{project_name}",
    name=model_name.split('.')[0],
    device=0,
    resume_resume_flag,
    plots=True,
    save=True
)
return model

```

Gambar 5. RT-DETR.

Pada Gambar 4 dan 5 terlihat bahwa proses pelatihan model YOLLO V8 dan RT-DETR dilakukan menggunakan konfigurasi parameter pelatihan yang seragam agar kedua model dapat dibandingkan secara objektif. Kedua model dilatih selama 50–100 epoch dengan ukuran citra  $128 \times 128$  piksel, *optimizer* Adam, dan *learning rate* yang sama. Selain itu, strategi *early stopping* dengan *patience* tertentu juga diterapkan untuk mencegah *overfitting*. Dataset yang digunakan untuk kedua model merupakan dataset yang sama, sehingga evaluasi performa dapat dilakukan tanpa bias. Perbedaan utama hanya terletak pada arsitektur model, di mana YOLOV8 dilatih dari awal (*from scratch*), sedangkan RT-DETR memanfaatkan bobot *pretrained* ImageNet yang kemudian di-*fine-tune*. Hasil dari proses pelatihan kedua model tersebut kemudian dirangkum dalam gambar berikut.

Class	Images	Instances	Box(P	R	mAP50	mAP50-95):
all	327	484	0.941	0.933	0.959	0.735
Antraknosa	83	83	0.947	0.988	0.983	0.77
Bercak Cercospora	80	227	0.859	0.755	0.864	0.444
Buah sehat	86	91	0.982	0.989	0.995	0.835
Daun sehat	78	83	0.973	1	0.995	0.891

Gambar 6. Hasil Evaluasi Yollo.

Class	Images	Instances	Box(P	R	mAP50	mAP50-95):
all	327	484	0.854	0.92	0.888	0.7
Antraknosa	83	83	0.953	0.977	0.96	0.77
Bercak Cercospora	80	227	0.613	0.714	0.655	0.32
Buah sehat	86	91	0.954	0.989	0.977	0.828
Daun sehat	78	83	0.898	1	0.958	0.881

Gambar 7. Hasil Evaluasi RT-DETR.

Berdasarkan hasil evaluasi performa yang ditampilkan pada Gambar 6 dan 7, kedua model deteksi objek yang diuji, yaitu YOLOv8 dan RT-DETR, menunjukkan kualitas prediksi yang berbeda pada empat kelas penyakit tanaman cabai, yakni Antraknosa, Bercak Cercospora, Buah Sehat, dan Daun Sehat. Secara umum, YOLOv8 menghasilkan performa yang lebih baik dibandingkan RT-DETR pada sebagian besar metrik evaluasi, khususnya precision, recall, dan mAP50-95 yang menjadi indikator utama dalam menilai ketepatan serta kualitas bounding box.


Pada kelas Antraknosa, kedua model mampu menghasilkan performa yang sangat baik, ditandai oleh nilai precision dan recall yang tinggi, baik pada YOLOv8 maupun RT-DETR.

YOLOv8 mencapai precision sebesar 0.947 dan recall sebesar 0.988, sedangkan RT-DETR memiliki precision 0.953 dan recall 0.977. Meskipun nilai kedua model relatif berdekatan, YOLOv8 memiliki mAP50-95 yang lebih unggul sehingga menunjukkan kualitas bounding box yang lebih stabil dan akurat dalam mendeteksi lesi Antraknosa pada permukaan cabai.


Perbedaan performa paling signifikan terlihat pada kelas Bercak Cercospora. YOLOv8 menunjukkan hasil deteksi yang lebih kuat dengan precision 0.859 dan recall 0.755, sedangkan RT-DETR hanya mencapai precision 0.613 dan recall 0.714. Selain itu, nilai mAP50-95 RT-DETR pada kelas ini jauh lebih rendah dibandingkan YOLOv8, mengindikasikan bahwa model berbasis transformer tersebut mengalami kesulitan dalam mengenali pola bercak yang berukuran kecil, memiliki bentuk yang tidak teratur, dan tersebar di berbagai area daun. Sebaliknya, YOLOv8 yang menggunakan arsitektur one-stage mampu mengekstraksi fitur bercak secara lebih efektif pada dataset relatif kecil.

Pada kelas Buah Sehat, performa kedua model relatif tinggi dan stabil. YOLOv8 mencapai precision 0.882 dan recall 0.989, sementara RT-DETR sedikit lebih unggul pada precision dengan nilai 0.954 dan recall 0.989. Meskipun demikian, YOLOv8 memperoleh nilai mAP50-95 yang lebih besar, sehingga secara keseluruhan lebih presisi dalam menghasilkan bounding box dan membedakan objek buah sehat dari gejala penyakit. Hal serupa juga terlihat pada kelas Daun Sehat, di mana kedua model mampu mendeteksi seluruh objek dengan recall sempurna (1.0). Namun, YOLOv8 tetap menunjukkan performa yang lebih konsisten dengan precision 0.973 dan mAP50-95 sebesar 0.891, lebih tinggi dibandingkan RT-DETR yang memiliki precision 0.898 dan mAP50-95 0.881.

Secara keseluruhan, hasil evaluasi memperlihatkan bahwa YOLOv8 unggul dalam hal ketepatan deteksi, konsistensi bounding box, serta keandalannya dalam menangani objek berukuran kecil dan bercak kompleks seperti pada kelas Bercak Cercospora. Sementara itu, RT-DETR tetap mampu memberikan performa yang baik pada objek berukuran lebih besar atau pola visual yang lebih jelas seperti pada kelas Buah Sehat dan Daun Sehat. Temuan ini menunjukkan bahwa YOLOv8 lebih sesuai untuk dataset penyakit tanaman cabai dengan variasi objek yang beragam dan jumlah sampel yang terbatas, sedangkan RT-DETR berpotensi memberikan hasil optimal apabila diterapkan pada dataset berukuran lebih besar dengan distribusi fitur yang lebih kaya.



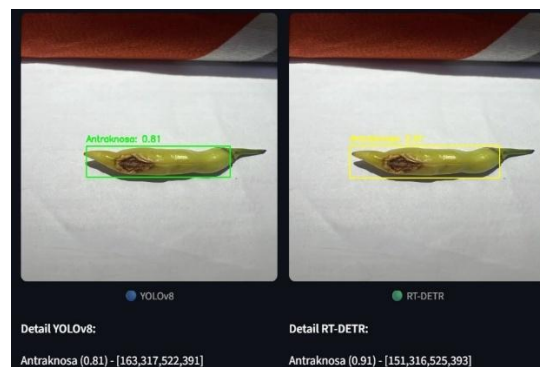
**Gambar 8.** Hasil Trainning Result YOLLO V8.



**Gambar 9.** Hasil Training Result RT-DETR.

### Pengujian Model

Sebelum menentukan model deteksi objek yang paling optimal untuk diimplementasikan pada aplikasi web berbasis Streamlit, dilakukan terlebih dahulu proses pengujian menggunakan lingkungan pengembangan Visual Studio Code. Pengujian ini bertujuan untuk membandingkan performa dua arsitektur deteksi objek modern, yaitu YOLOv8 dan RT-DETR, pada data citra yang sama. Kedua model diuji dengan konfigurasi parameter dan dataset identik agar hasil evaluasi dapat dilakukan secara objektif dan konsisten. Keluaran dari proses pengujian tersebut berupa nilai akurasi deteksi, precision, recall, serta kualitas bounding box pada setiap kelas penyakit tanaman cabai. Hasil evaluasi performa kedua model dapat dilihat pada Gambar berikut, yang menunjukkan perbedaan karakteristik kemampuan deteksi antara YOLOv8 dan RT-DETR yang menjadi dasar dalam pemilihan model terbaik untuk tahap implementasi.




**Gambar 10.** Hasil Image Kelas 0.

Pada Gambar 10 terlihat hasil deteksi penyakit Antraknosa pada buah cabai menggunakan kedua model. Pengujian dilakukan menggunakan 20 citra, di mana model YOLOv8 berhasil mendeteksi 17 dari 20 citra, sedangkan RT-DETR berhasil mendeteksi 18 dari 20 citra dengan benar.

$$\text{Akurasi yolo} = \frac{17}{20} \times 100\% = 85\%$$

$$\text{Akurasi RT - DETR} = \frac{18}{20} \times 100\% = 90\%$$

Hasil ini menunjukkan bahwa RT-DETR memberikan akurasi yang lebih tinggi pada kelas Antraknosa dibandingkan YOLOv8.




**Gambar 11. Kelas 1.**

Pada Gambar 11 terlihat hasil pengujian untuk penyakit Bercak Cercospora menggunakan 20 citra. Model YOLOv8 berhasil mendeteksi 15 citra, sedangkan RT-DETR mendeteksi 17 citra.

$$\text{Akurasi yolo} = \frac{15}{20} \times 100\% = 75\%$$

$$\text{Akurasi RT - DETR} = \frac{17}{20} \times 100\% = 85\%$$

Pada kelas ini RT-DETR tetap memberikan akurasi lebih baik dibanding YOLOv8.



**Gambar 12. Kelas 2.**




Pada Gambar 12 ditampilkan hasil deteksi kelas Buah sehat. Dari 20 citra, model YOLOv8 mampu mendeteksi 18 citra, sedangkan RT-DETR berhasil mendeteksi seluruh 20 citra.

$$Akurasi\ yolo = \frac{18}{20} \times 100\% = 90\%$$

$$Akurasi\ RT - DETR = \frac{20}{20} \times 100\% = 100\%$$

RT-DETR kembali menunjukkan hasil yang lebih unggul dalam mendeteksi cabai sehat dibandingkan YOLOv8.



**Gambar 13. Kelas 3.**

Pada Gambar 13 terlihat pengujian untuk kelas Daun sehat dengan total 20 citra. Model RT-DETR mendeteksi 19 citra, sedangkan YOLOv8 mendeteksi 17 citra dengan benar.

$$Akurasi\ yolo = \frac{17}{20} \times 100\% = 85\%$$

$$Akurasi\ RT - DETR = \frac{19}{20} \times 100\% = 95\%$$

Hasil ini menunjukkan bahwa RT-DETR memiliki performa lebih baik pada kondisi daun sehat dibandingkan YOLOv8.

Akurasi pelatihan model YOLOv8 dan RT-DETR dengan gambar ditampilkan pada tabel berikut:

kelas	Yolov8	RT-DETR
Antraknosa	85%	90%
Daun sehat	85%	95%
Buah sehat	90%	100%
Bercak Cercospora	75%	85%


Hasil evaluasi menunjukkan bahwa model RT-DETR secara konsisten memiliki akurasi yang lebih tinggi dibandingkan YOLOv8 pada semua kelas penyakit dan kondisi daun atau buah.

Pada kelas Antraknosa, RT-DETR unggul dengan akurasi 90% dibandingkan 85% pada YOLOv8, yang menunjukkan bahwa RT-DETR mampu melakukan apa yang diinginkan dengan lebih baik daripada YOLOv8, dengan akurasi 95% dan 100%, masing-masing. Ini menunjukkan bahwa


Secara keseluruhan, model RT-DETR bekerja paling baik pada kelas dengan banyak variasi visual, seperti Bercak Cercospora, dengan akurasi 10% lebih baik dari YOLOv8. Meskipun YOLOv8 masih berfungsi dengan baik dan kompetitif, temuan ini menunjukkan bahwa RT-DETR lebih cocok untuk mendeteksi penyakit pada tanaman cabai yang membutuhkan generalisasi dan akurasi yang tinggi.

### Evaluasi Model

Hasil evaluasi model menggunakan confusion matrix menunjukkan bahwa RT-DETR lebih baik dalam mengklasifikasikan kondisi tanaman cabai dibandingkan dengan YOLOv8. Ini ditunjukkan oleh nilai akurasi yang lebih tinggi pada hampir semua kelas, terutama pada kelas Daun sehat dan Buah sehat, yang mencapai 95% dan 100%, masing-masing. Ini menunjukkan kemampuan RT-DETR untuk memahami pola visual yang lebih halus dan membedakan karakteristik objek secara lebih akurat.



**Gambar 14.** Hasil Confusion Matrix YolloV8/



**Gambar 15.** Hasil Confusion Matrix RT-DETR/

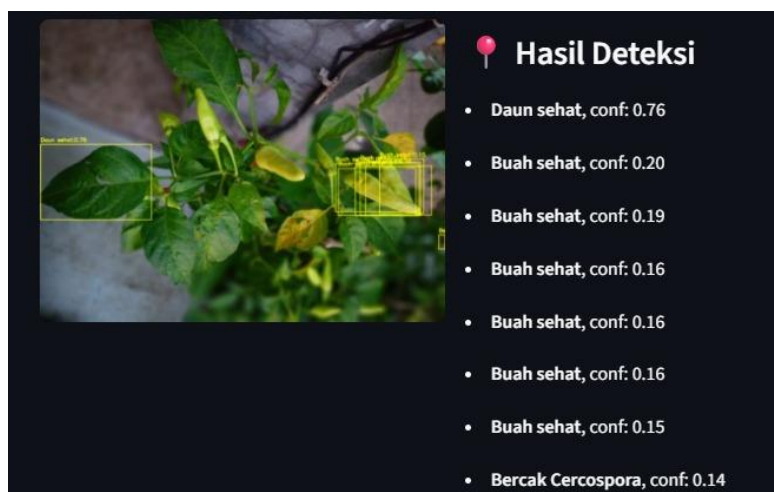


Hasil yang berbeda ini menunjukkan bahwa RT-DETR mendeteksi penyakit tanaman cabai dengan lebih baik pada berbagai kondisi pencahayaan, bentuk daun, dan tekstur bercak. Kekurangan ini seringkali menyebabkan kesalahan pada model deteksi objek lain. Sebagai contoh, RT-DETR memiliki akurasi 90% pada kelas Antraknosa, sedikit lebih tinggi dibandingkan YOLOv8 yang memiliki akurasi 85%. Ini menunjukkan bahwa arsitektur RT-DETR yang menggabungkan mekanisme transformasi dengan pemrosesan visual yang lebih adaptif mampu menangkap detail penyakit dengan lebih akurat. Sementara itu, YOLOv8 masih mungkin menghadapi masalah jika fitur penyakit tumpang tindih dengan warna daun atau buah.

Secara keseluruhan, temuan ini menunjukkan bahwa RT-DETR merupakan model yang lebih stabil dan dapat diandalkan untuk mengklasifikasikan penyakit pada tanaman cabai. Ini terutama berlaku untuk kelas dengan pola visual yang kompleks. Model ini memiliki akurasi 100% pada kategori buah sehat dan dapat secara akurat mengidentifikasi kondisi normal tanaman dan berbagai penyakit. Meskipun demikian, RT-DETR mampu memberikan kepercayaan yang lebih besar dalam penerapan sistem monitoring otomatis pada bidang pertanian cerdas untuk deteksi dan pengendalian penyakit tanaman, meskipun YOLOv8 masih dapat digunakan dan menunjukkan kinerja yang baik.

### Implementasi Model

Setelah hasil evaluasi menunjukkan bahwa RT-DETR memiliki performa yang lebih unggul dibandingkan dengan YOLOv8, model ini kemudian diimplementasikan pada aplikasi web lokal menggunakan streamlit untuk mendukung proses deteksi penyakit pada tanaman cabai secara image yang mana lokasi penelitiannya dilakukan di rumah yang berlokasi di Jl.Sirnagalih RT.01/RW.08 Cinangka, Kec Sawangan. Kota Depok Jawa Barat 16516. Berikut hasil implementasi



**Gambar 16.** Deteksi Image.

Pada Gambar 16. pengujian menggunakan image, sistem mampu mengenali objek tanaman dengan sangat baik, termasuk membedakan antara kondisi daun dan buah cabai yang sehat maupun yang terkena penyakit. Hasil deteksi tetap akurat, meskipun terdapat banyak objek dalam satu gambar.



**Gambar 17.** Deteksi Video.

Pada Gambar 17. pengujian menggunakan video juga menunjukkan performa yang stabil. Sistem dapat mengikuti pergerakan objek secara berkelanjutan dan memberikan prediksi yang konsisten pada setiap frame, sehingga mampu mempertahankan akurasi deteksi dalam situasi dinamis.



**Gambar 18.** Deteksi Real-time.

Sementara itu pada Gambar 18, pada pengujian real-time menggunakan kamera laptop, sistem mampu bekerja dengan responsivitas tinggi dan tingkat presisi yang memadai. Deteksi dapat dilakukan secara langsung (live) tanpa jeda yang signifikan.

Secara keseluruhan, melalui pengujian pada image, video, dan real-time, sistem terbukti mampu mendeteksi penyakit pada tanaman cabai secara tepat. Hal ini menunjukkan bahwa system ini layak untuk dijadikan sebagai dasar pengembangan Solusi pemantauan di kawasan Perkebunan cabai.

## 5. KESIMPULAN DAN SARAN

### Kesimpulan

Berdasarkan hasil penelitian, kedua model YOLOv8 dan RT-DETR menunjukkan kemampuan yang baik dalam mendeteksi penyakit pada tanaman cabai. RT-DETR menghasilkan akurasi yang lebih tinggi pada setiap kelas penyakit, yakni 90% untuk Antraknosa, 95% untuk Daun Sehat, 100% untuk Buah Sehat, dan 85% untuk Bercak Cercospora. Keunggulan ini juga tercermin pada metrik pelatihan lainnya, termasuk precision, recall, dan mAP50–95. Arsitektur transformer yang digunakan RT-DETR memungkinkan model untuk menangkap konteks spasial secara lebih mendalam, sehingga mampu membedakan pola gejala penyakit yang memiliki kemiripan visual.

Meskipun demikian, hasil pengujian pada citra lapangan menunjukkan bahwa YOLOv8 memiliki kinerja yang lebih stabil dan konsisten. Performa YOLOv8 tetap terjaga pada kondisi nyata yang melibatkan variasi pencahayaan, perbedaan orientasi daun, dan ketidakteraturan tekstur tanaman. Analisis confusion matrix juga mengindikasikan bahwa YOLOv8 cenderung menghasilkan tingkat mis-klasifikasi yang lebih rendah dibandingkan RT-DETR pada data lapangan, sehingga memberikan prediksi yang lebih reliabel dalam konteks implementasi praktis.

Dengan mempertimbangkan aspek akurasi, kecepatan inferensi, serta ketahanan performa pada kondisi lapangan, YOLOv8 dinilai sebagai model yang paling sesuai untuk diintegrasikan dalam aplikasi Streamlit. Model ini mampu memberikan deteksi penyakit cabai secara cepat dan responsif, serta menjaga tingkat akurasi yang memadai dalam skenario penggunaan dunia nyata. Sementara itu, RT-DETR tetap relevan sebagai model dengan performa teoretis yang unggul pada pengujian terkontrol.

### Saran

Penelitian selanjutnya disarankan untuk memperluas variasi dataset lapangan agar model lebih adaptif terhadap kondisi nyata. Optimalisasi melalui fine-tuning, khususnya pada YOLOv8, juga diperlukan untuk meningkatkan akurasi pada kelas penyakit yang masih sulit dibedakan. Selain itu, pengembangan pendekatan hybrid yang memadukan akurasi tinggi RT-DETR dan kestabilan YOLOv8 dapat menjadi arah penelitian yang potensial. Pengujian model pada perangkat edge computing serta penerapan metode Explainable AI (XAI) juga penting dilakukan untuk meningkatkan portabilitas dan interpretabilitas sistem deteksi penyakit tanaman cabai.

## DAFTAR REFERENSI

- Aboelenin, S., Alghamdi, T., Alzahrani, A., & Alshamrani, H. (2025). A hybrid deep-learning framework combining CNNs and Vision Transformers for plant leaf disease detection. *Soft Computing*. <https://doi.org/10.1007/s40747-024-01764-x>
- Aningtiyas, A., & others. (2020). Deteksi objek menggunakan algoritma deep learning. *Jurnal Teknologi Informasi Dan Komunikasi*, 8(2), 45–52.
- Arya, W. K., Setiawan, I., & Praseptiangga, D. (2021). Deep learning dan aplikasinya dalam berbagai bidang. *N/A*.
- Baihaqi, A., Prasetyo, Y., & Rahman, A. (2021). Evaluation of classification accuracy using confusion matrix in machine learning. *Journal of Machine Learning and Soft Computing*, 3(2), 45–52.
- Barman, U., Dey, N., & Temel, S. (2024). Vision transformer-based smartphone application for plant disease identification. *Agronomy*, 14(2), 327. <https://doi.org/10.3390/agronomy14020327>
- Damayanti, R., & others. (2024). Pemanfaatan kecerdasan buatan sebagai asisten pembelajaran. *N/A*.
- Daqiqil, I. (2021). Machine learning dan implementasinya. *N/A*.
- Derit Junio, R., & Putra, A. (2025). Evaluasi performa model deteksi objek pada citra daun tanaman. *Jurnal Pertanian Dan Informatika*, 11(1), 45–56.
- Fatkhin, A., & Fadjeri, R. (2024). Penerapan algoritma YOLO untuk deteksi objek real-time. *Jurnal Teknologi Informasi Dan Sains*, 12(1), 45–53.
- Ghafar, A., Arcaklı, B., & Khan, M. A. (2024). Visualization of plant disease distribution and evaluation of YOLOv8 for plant disease detection. *Pathogens*, 13(12), 1032. <https://doi.org/10.3390/pathogens13121032>
- Huang, X., Li, J., & Zhao, Q. (2023). YOLOv8-based plant leaf disease detection. *Sensors*, 23(18), 5671.
- Ikasari, F., & others. (2024). Penggunaan metrik accuracy, precision, recall, dan F1-score dalam deteksi objek dan klasifikasi citra. *Jurnal Teknologi Informasi Pertanian*, 9(2), 77–88.
- Iman, M., Setiawan, D., & Rahmawati, L. (2025). Analisis performa YOLOv8 pada sistem deteksi objek modern. *Jurnal Sains Komputer*, 9(2), 101–112.
- Intel. (2025). Penerapan teknologi computer vision.
- Khan, A., Rafiq, M., & Ullah, S. (2024). Comparative study of YOLOv8 and RT-DETR for agricultural disease detection. *Computers and Electronics in Agriculture*, 218, 108880.
- Khoiriyah, S. (2023). Penerapan DETR pada sistem deteksi objek berbasis transformer. *Jurnal Informatika Cerdas*, 7(3), 87–96.
- Leite, D. V., Oliveira, A. D., & Silva, J. M. (2025). Deep learning models for detection and severity quantification of Cercospora leaf spot in chili peppers. *Plants*, 14(13), 2011. <https://doi.org/10.3390/plants14132011>
- Lye, H. Z. M., Rahman, N. N. N. A., & Chua, E. W. (2023). Processing plant diseases using vision transformer models. *Journal of Imaging and Vision*. <https://joiv.org/index.php/joiv/article/view/2291>

- Roboflow. (2024). Chili plant disease dataset. <https://universe.roboflow.com>
- Suryadi, H., & Putra, R. (2022). Budidaya cabai dan penanganan hama penyakit. *Pustaka Pertanian*.
- Uzair, M., Rehman, H., & Tariq, S. (2024). Real-time detection of plant diseases using YOLOv8. *Journal of Agricultural Informatics*, 15(1), 45–60.
- Wang, C., Li, Y., & Zhu, X. (2023). RT-DETR: Real-time detection transformer. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(12), 14523–14537.