



# Klasifikasi Penyakit Pada Buah Jambu Biji Menggunakan Algoritma Yolo V5

Nadiya Rezika<sup>1</sup>, Elmayati<sup>2</sup>, Novi Lestari\*<sup>3</sup>

<sup>1,2,3</sup>Fakultas Ilmu Teknik, Universitas Bina Insan, Lubuklinggau, Indonesia

E-mail : novi\_lestari@muralinggau.ac.id\*

\*Penulis Korespondensi

Received 27 October 2025; Revised 16 November 2025; Accepted 17 November 2025

**Abstrak** - Pertanian hortikultura, khususnya jambu biji (*Psidium guajava*), memiliki potensi ekonomi besar di Indonesia. Namun, produktivitas sering menurun akibat serangan penyakit pada buah, yang selama ini masih didiagnosis secara manual oleh petani. Penelitian ini bertujuan mengembangkan sistem klasifikasi penyakit jambu biji berbasis kecerdasan buatan menggunakan algoritma You Only Look Once (YOLO) versi 5. Dataset terdiri dari 600 citra yang terbagi dalam tiga kelas penyakit: Phytophthora, Styler and Root, dan Scab. Data dikumpulkan melalui dokumentasi lapangan, kemudian dilakukan preprocessing dan augmentasi menggunakan Roboflow. Dataset dibagi menjadi 70% data pelatihan, 20% validasi, dan 10% pengujian. Model YOLOv5 dilatih menggunakan Google Colaboratory dan dievaluasi secara konsisten menggunakan Confusion Matrix serta metrik akurasi, presisi, recall, dan F1-score. Hasil pengujian menunjukkan bahwa model mencapai akurasi lebih dari 95% dengan nilai presisi, recall, dan F1-score yang tinggi pada setiap kelas penyakit. Hal ini membuktikan bahwa YOLOv5 efektif digunakan untuk deteksi penyakit jambu biji secara real-time. Penelitian ini memberikan kontribusi dalam penerapan teknologi kecerdasan buatan untuk membantu petani melakukan diagnosis dini secara cepat dan akurat, sehingga dapat mengurangi risiko penurunan hasil panen.

**Kata Kunci:** YOLOv5, Jambu Biji, Klasifikasi Penyakit, Deep Learning, Deteksi Objek.

**Abstract** - Horticultural agriculture, especially guava (*Psidium guajava*), has great economic potential in Indonesia. However, productivity often declines due to fruit disease attacks, which are still manually diagnosed by farmers. This study aims to develop an artificial intelligence-based guava disease classification system using the You Only Look Once (YOLO) version 5 algorithm. The dataset consists of 600 images divided into three disease classes: Phytophthora, Styler and Root, and Scab. Data were collected through field documentation, then preprocessed and augmented using Roboflow. The dataset was divided into 70% training data, 20% validation, and 10% testing. The YOLOv5 model was trained using Google Collaboratory and consistently evaluated using the Confusion Matrix and accuracy, precision, recall, and F1-score metrics. The test results showed that the model achieved an accuracy of more than 95% with high precision, recall, and F1-score values for each disease class. This proves that YOLOv5 is effective for real-time guava disease detection. This research contributes to the application of artificial intelligence technology to help farmers make early diagnoses quickly and accurately, thereby reducing the risk of reduced crop yields.

**Keywords:** YOLOv5, Guava, Disease Classification, Deep Learning, Object Detection.



## 1. PENDAHULUAN

---

Indonesia dikenal sebagai negara agraris yang sebagian besar penduduknya menggantungkan kehidupan pada sektor pertanian. Sektor ini berperan penting dalam menyediakan bahan pangan, membuka lapangan kerja, serta menjadi sumber pendapatan utama bagi masyarakat pedesaan. Selain itu, sektor pertanian juga memiliki kontribusi signifikan terhadap Produk Domestik Bruto (PDB) nasional dan menjadi penopang stabilitas ekonomi, terutama ketika terjadi ketidakpastian global. Salah satu subsektor yang memiliki peranan penting dalam struktur pertanian Indonesia adalah hortikultura, yang mencakup tanaman buah, sayuran, bunga, dan tanaman obat-obatan. Subsektor ini dikenal bernilai ekonomi tinggi dan memiliki prospek ekspor yang menjanjikan karena permintaan pasar yang terus meningkat baik di dalam maupun luar negeri (Fadhilah et al., 2018)

Salah satu komoditas hortikultura yang potensial adalah jambu biji (*Psidium guajava* L.), yang memiliki nilai ekonomi dan manfaat kesehatan tinggi. Jambu biji kaya akan vitamin C, serat, serta antioksidan, sehingga banyak dikonsumsi untuk meningkatkan daya tahan tubuh dan menjaga kesehatan. Selain dikonsumsi langsung, jambu biji juga dimanfaatkan dalam industri pangan, kosmetik, dan farmasi. Berbagai penelitian menunjukkan bahwa karakterisasi tanaman jambu biji di beberapa daerah Indonesia menunjukkan variasi morfologi dan produktivitas yang tinggi, menandakan potensi pengembangan komoditas ini secara luas (Fadhilah et al., 2018).

Namun demikian, produktivitas jambu biji di lapangan sering mengalami penurunan yang signifikan akibat serangan penyakit pada daun maupun buah. Beberapa penyakit umum yang menyerang tanaman jambu biji antara lain *Phytophthora*, *Styler and Root*, dan *Scab* atau bercak buah (Kurniawati & Kumala, 2021). Penyakit-penyakit tersebut dapat menyebabkan gejala berupa bercak hitam, pembusukan, deformasi, dan kerontokan buah sebelum masa panen, sehingga menurunkan kualitas dan kuantitas hasil produksi. Metode diagnosis tradisional yang dilakukan dengan pengamatan visual oleh petani cenderung subjektif, membutuhkan waktu lama, serta rentan terhadap kesalahan identifikasi (Umar, 2021). Akibatnya, penanganan penyakit sering terlambat, menyebabkan kerugian ekonomi yang besar bagi petani.

Seiring dengan kemajuan teknologi informasi, kecerdasan buatan (*Artificial Intelligence/AI*) memberikan peluang besar dalam meningkatkan efisiensi dan efektivitas sektor pertanian. Penerapan AI pada bidang pertanian dikenal dengan istilah *smart farming* atau *precision agriculture*, di mana teknologi digunakan untuk melakukan pemantauan, analisis, dan pengambilan keputusan berbasis data. Salah satu cabang AI yang berperan penting adalah *deep learning*, yang memungkinkan komputer mempelajari pola kompleks dari citra digital secara otomatis. Dalam konteks pertanian, *deep learning* telah digunakan untuk klasifikasi penyakit tanaman melalui pengenalan citra daun dan buah secara cepat dan akurat (Ilahiyah & Nilogiri, 2018).

Untuk mengatasi keterbatasan metode klasifikasi berbasis CNN murni yang hanya mampu mengenali kelas tanpa mengetahui lokasi objek, pendekatan *object detection* berbasis *deep learning* mulai banyak digunakan. Salah satu algoritma yang paling populer adalah *You Only Look Once (YOLO)*, yaitu metode deteksi objek berbasis *convolutional neural network (CNN)* yang mampu melakukan proses deteksi dan klasifikasi secara bersamaan dalam satu tahap (*single-stage detection*). YOLO unggul dalam kecepatan inferensi dan tetap mempertahankan tingkat akurasi yang tinggi, sehingga sangat sesuai untuk aplikasi *real-time* (Hidayah et al., 2023). Versi pengembangannya, YOLOv5, hadir dengan arsitektur yang lebih ringan, modular, dan mudah diadaptasi. Selain itu, YOLOv5 dapat diimplementasikan secara efisien pada platform komputasi awan seperti Google Colaboratory dan mendukung integrasi dengan Roboflow untuk pengelolaan dataset, anotasi, serta augmentasi citra yang lebih terstruktur (Mira et al., 2023).



Untuk mengatasi hal tersebut, metode object detection berbasis deep learning mulai banyak digunakan. Salah satu algoritma yang paling populer adalah You Only Look Once (YOLO), yang mampu melakukan deteksi dan klasifikasi objek secara bersamaan dalam satu tahap proses (single-stage). YOLO dikenal memiliki keunggulan dalam hal kecepatan dan akurasi, terutama untuk deteksi citra secara real-time (Hidayah et al., 2023). Versi terbaru, yaitu YOLOv5, ditulis dalam bahasa Python dengan arsitektur yang lebih ringan dan fleksibel. YOLOv5 mudah diimplementasikan pada platform berbasis cloud seperti Google Colaboratory, serta mendukung integrasi dengan Roboflow untuk pengelolaan dataset, anotasi, dan augmentasi citra secara efisien (Mira et al., 2023).

Dalam penelitian ini, YOLOv5 digunakan untuk mendeteksi tiga jenis penyakit pada buah jambu biji, yaitu Phytophthora, Styler and Root, dan Scab (bercak buah). Dataset yang digunakan terdiri dari 600 citra, dengan distribusi seimbang sebanyak 200 citra untuk setiap kelas penyakit. Seluruh citra diperoleh melalui dokumentasi lapangan menggunakan kamera smartphone dengan pencahayaan alami, sehingga dapat merepresentasikan kondisi nyata di kebun petani. Penelitian ini bertujuan mengembangkan model deteksi penyakit jambu biji berbasis deep learning yang mampu bekerja secara *real-time* dan memberikan hasil klasifikasi yang akurat untuk mendukung proses diagnosis dini di lapangan.

1. Mengembangkan sistem klasifikasi penyakit jambu biji menggunakan algoritma YOLOv5.
2. Menganalisis kinerja model berdasarkan metrik evaluasi yang konsisten, yaitu akurasi, precision, recall, dan F1-score.
3. Mengimplementasikan model deteksi penyakit secara real-time agar dapat digunakan langsung oleh petani.
4. Hasil penelitian ini diharapkan mampu menjadi langkah awal dalam penerapan teknologi kecerdasan buatan di bidang hortikultura, khususnya dalam pengendalian penyakit tanaman jambu biji. Dengan adanya sistem deteksi otomatis, petani dapat melakukan diagnosis dini secara cepat dan akurat tanpa perlu keahlian khusus. Selain itu, penelitian ini juga menjadi kontribusi nyata dalam pengembangan pertanian cerdas (*smart agriculture*) yang mendukung peningkatan produktivitas dan keberlanjutan sektor pertanian Indonesia di era digital (Maso et al., 2015; Rachmawati & Widhyaestoeti, 2020).

## 2. METODE PENELITIAN

---

### 2.1 Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen. Pemilihan metode eksperimen didasarkan pada kebutuhan untuk menguji performa algoritma YOLOv5 dalam melakukan klasifikasi penyakit jambu biji secara real-time. Secara umum, proses penelitian terdiri atas empat tahap utama, yaitu: (1) pengumpulan data, (2) pengolahan data, (3) pembangunan model, dan (4) evaluasi model.

Keempat tahapan tersebut dijalankan secara berurutan. Pertama, peneliti melakukan akuisisi citra buah jambu biji yang terindikasi penyakit. Kedua, citra yang diperoleh diolah melalui proses *preprocessing* seperti *resize* ke ukuran  $640 \times 640$  piksel, pemberian label menggunakan bounding box, serta augmentasi untuk meningkatkan variasi data. Ketiga, dataset yang telah diproses digunakan untuk melatih model YOLOv5 pada platform Google Colaboratory dengan parameter tertentu. Tahap terakhir adalah evaluasi model menggunakan Confusion Matrix beserta metrik akurasi, presisi, recall, dan F1-score, yang dipilih karena lebih sesuai dalam mengukur kinerja model deteksi objek dibandingkan metrik regresi seperti MAE dan RMSE.




## 2.2 Dataset dan Preprocessing

Dataset penelitian terdiri atas 600 citra buah jambu biji dengan distribusi yang seimbang, yakni 200 citra untuk masing-masing kelas penyakit. Seluruh citra diambil menggunakan kamera smartphone dengan pencahayaan alami.

Proses *preprocessing* dilakukan dalam beberapa tahap:

1. Resize citra ke ukuran  $640 \times 640$  piksel agar sesuai dengan format input YOLOv5.
2. Labeling citra dengan bounding box menggunakan Roboflow, untuk menandai area penyakit.
3. Augmentasi citra, meliputi rotasi, flipping horizontal dan vertikal, penyesuaian kecerahan, serta perubahan kontras. Tujuan augmentasi adalah memperkaya variasi dataset dan mengurangi risiko *overfitting*.
4. Split dataset ke dalam tiga subset, yaitu 70% untuk data latih, 20% untuk data validasi, dan 10% untuk data uji.



**Gambar 1.** Contoh hasil labeling dataset menggunakan Roboflow

## 2.3 Algoritma YOLOv5

YOLOv5 merupakan model deteksi objek generasi kelima dari keluarga YOLO (*You Only Look Once*). Model ini menggunakan arsitektur CNN dengan tiga komponen utama:

1. Backbone, yang berfungsi mengekstraksi fitur dari citra masukan melalui lapisan konvolusi.
2. Neck, yang menggabungkan fitur dari berbagai skala menggunakan *Feature Pyramid Network (FPN)* dan *Path Aggregation Network (PAN)*.
3. Head, yang menghasilkan prediksi bounding box dan probabilitas kelas.

Secara matematis, YOLOv5 memprediksi bounding box berdasarkan parameter koordinat ( $x, y, w, h$ ) serta probabilitas kelas ( $p$ ). Prediksi akhir ditentukan dengan fungsi:

$$P(\text{Class} | \text{Object}) \times P(\text{Object}) = \text{Confidence} \times \text{Class\_Probability}$$

Parameter pelatihan yang digunakan dalam penelitian ini adalah *batch size* 16, jumlah *epoch* 100, dan *learning rate* 0.001. Proses pelatihan dilakukan menggunakan Google Colaboratory dengan dukungan GPU untuk mempercepat komputasi.

## 2.4 Metode Evaluasi

Evaluasi performa model dilakukan melalui Confusion Matrix dan beberapa metrik turunan. Confusion Matrix terdiri dari empat komponen utama: True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Dari keempat nilai tersebut, dihitung metrik sebagai berikut:

1. Akurasi

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN}$$



2. Precision

$$Precision = \frac{TP}{TP + FP}$$

3. Recall

$$Recall = \frac{TP}{TP + FN}$$

4. F1-Score

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + recall}$$

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Hasil Pelatihan Model

Proses pelatihan model YOLOv5 dilakukan pada platform Google Colaboratory dengan dukungan GPU. Dataset yang terdiri dari 600 citra dibagi menjadi 70% untuk pelatihan (420 citra), 20% untuk validasi (120 citra), dan 10% untuk pengujian (60 citra). Parameter pelatihan yang digunakan adalah *batch size* = 16, *epoch* = 100, dan *learning rate* = 0.001.

Selama proses pelatihan, nilai *loss function* menurun secara konsisten seiring dengan bertambahnya jumlah epoch. Penurunan ini menunjukkan bahwa model mampu belajar secara efektif dari dataset yang diberikan. Pada akhir pelatihan, model berhasil mencapai nilai *loss* yang relatif stabil, menandakan tidak terjadi *overfitting*.

```
149/149 4.56G 0.004532 0.00517 0.004383 43 640: 88% 50/57 [00:10<00:01, 4.7
with torch.cuda.amp.autocast(amp):
149/149 4.56G 0.004512 0.005143 0.004379 48 640: 89% 51/57 [00:10<00:01, 4.7
with torch.cuda.amp.autocast(amp):
149/149 4.56G 0.004488 0.00513 0.004399 45 640: 91% 52/57 [00:10<00:01, 4.7
with torch.cuda.amp.autocast(amp):
149/149 4.56G 0.004503 0.005111 0.004364 52 640: 93% 53/57 [00:11<00:00, 4.6
with torch.cuda.amp.autocast(amp):
149/149 4.56G 0.004503 0.005126 0.004346 55 640: 95% 54/57 [00:11<00:00, 4.7
with torch.cuda.amp.autocast(amp):
149/149 4.56G 0.004487 0.005109 0.004304 39 640: 96% 55/57 [00:11<00:00, 4.7
with torch.cuda.amp.autocast(amp):
149/149 4.56G 0.004468 0.005078 0.004255 46 640: 98% 56/57 [00:11<00:00, 4.8
with torch.cuda.amp.autocast(amp):
149/149 4.56G 0.004519 0.00513 0.004329 12 640: 100% 57/57 [00:11<00:00, 4.8
Class Images Instances P R mAP50 mAP50-95: 100% 8/8 [00:02<00:00
all 240 240 0.893 0.945 0.938 0.862
```

Gambar 2. Grafik penurunan training loss dan validation loss selama proses pelatihan

#### 3.2 Evaluasi Model dengan Confusion Matrix

Dari hasil evaluasi pada dataset uji (test set), Confusion Matrix menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik pada ketiga kelas penyakit. Nilai diagonal mendominasi, yang berarti sebagian besar citra berhasil diklasifikasikan dengan benar. Berdasarkan hasil perhitungan, diperoleh performa sebagai berikut:

Phytophthora : presisi tinggi dan nilai recall mencapai 98%

Scab : recall sebesar 96% dengan tingkat kesalahan prediksi sangat rendah

Styler and Root: model mencapai recall 100% pada dataset uji

F1-score : pada ketiga kelas berada pada rentang sangat tinggi (di atas 0.95)


Meskipun performa ini menunjukkan kemampuan model yang kuat, nilai recall yang mencapai 100% pada kelas Styler and Root perlu dianalisis lebih lanjut. Akurasi yang terlalu tinggi dapat menjadi indikasi adanya:

1. Overfitting, jika model terlalu pas terhadap data latih atau validasi.
2. Ciri visual kelas tertentu yang sangat khas, sehingga model sangat mudah membedakannya.
3. Distribusi dataset yang mungkin kurang bervariasi, misalnya latar belakang sangat homogen.



Oleh karena itu, penting untuk memastikan bahwa:

- Evaluasi dilakukan murni pada data uji yang tidak pernah dilihat model sebelumnya.
- Dataset memiliki variasi yang cukup, baik dari pencahayaan, sudut pengambilan, maupun kondisi buah.
- Model tidak hanya menghafal pola spesifik, tetapi benar-benar belajar generalisasi.



**Gambar 3.** Confusion Matrix YOLOv5 pada dataset uji

Meskipun performa model secara umum sangat baik, masih ditemukan beberapa kesalahan klasifikasi pada citra yang memiliki gejala penyakit sangat samar atau berada dalam kondisi pencahayaan yang kurang optimal. Situasi ini menyebabkan model kesulitan membedakan pola visual antar kelas penyakit, terutama ketika tekstur dan warna buah tampak serupa. Faktor kualitas citra seperti bayangan, noise, dan sudut pengambilan gambar juga turut memengaruhi akurasi prediksi. Secara keseluruhan, nilai akurasi rata-rata model untuk seluruh kelas penyakit mencapai 90,6%, yang menunjukkan performa yang cukup tinggi untuk digunakan dalam konteks lapangan. Dengan demikian, model YOLOv5 yang dikembangkan memiliki potensi kuat untuk mendukung diagnosis penyakit jambu biji secara cepat dan praktis, meskipun peningkatan kualitas dataset tetap diperlukan untuk hasil yang lebih optimal.

### 3.3 Evaluasi dengan Precision, Recall, F1, dan mAP

Selain Confusion Matrix, model dievaluasi menggunakan metrik precision, recall, F1-score, dan mean average precision (mAP). Hasil evaluasi dapat dilihat pada Tabel 1 berikut.




**Tabel 1.** Hasil evaluasi YOLOv5 per kelas penyakit jambu biji

Kelas	Jumlah Citra	Jumlah Instance	Precision	Recall	mAP	Akurasi
Phytophthora	120	41	0.976	0.974	0.986	0.928
Scab	120	47	1.000	0.947	0.991	0.943
Styler & Root	120	32	0.941	0.992	0.942	0.846
Rata-rata	120	120	0.972	0.971	0.973	0.906


Berdasarkan tabel di atas, kelas *Scab* memiliki precision tertinggi (100%), artinya seluruh prediksi positif untuk kelas ini benar adanya. Sementara kelas *Styler and Root* memiliki recall tertinggi (99,2%), menunjukkan kemampuan model yang sangat baik dalam mendeteksi hampir seluruh kasus penyakit tersebut, meskipun precision-nya sedikit lebih rendah. Nilai rata-rata mAP mencapai 97,3%, yang menandakan tingkat akurasi deteksi objek sangat tinggi.

### 3.4 Kurva Evaluasi (Precision, Recall, dan F1-Confidence)


Untuk memperdalam analisis, digunakan grafik kurva yang menghubungkan confidence level dengan nilai metrik evaluasi.



**Gambar 4.** Kurva F1-Confidence YOLOv5



**Gambar 5.** Kurva Precision-Confidence YOLOv5



**Gambar 6.** Kurva Recall-Confidence YOLOv5

Berdasarkan kurva pada Gambar 6–8:

1. Nilai F1-Score mencapai titik optimal sebesar 0.97 pada confidence 0.537. Hal ini berarti bahwa keseimbangan terbaik antara precision dan recall terjadi ketika ambang confidence ditetapkan pada nilai tersebut.
2. Nilai precision maksimum dicapai pada confidence 0.948 dengan nilai 1.00 untuk seluruh kelas, menandakan model tidak menghasilkan prediksi palsu pada tingkat keyakinan tinggi.
3. Nilai recall stabil pada kisaran 0.95–1.00 hingga confidence 0.6, kemudian menurun tajam ketika confidence mendekati 1. Hal ini menunjukkan bahwa jika model dipaksa untuk hanya menerima prediksi dengan tingkat keyakinan sangat tinggi, ada kemungkinan sebagian kasus penyakit tidak terdeteksi.

Dengan demikian, pemilihan ambang confidence pada kisaran 0.5–0.6 merupakan titik optimal untuk mencapai keseimbangan antara precision dan recall.

### 3.5 Diskusi Hasil Penelitian

Secara umum, penelitian ini berhasil membuktikan bahwa YOLOv5 dapat digunakan untuk mendeteksi penyakit jambu biji secara efektif. Hasil evaluasi menunjukkan bahwa algoritma mampu mencapai akurasi keseluruhan 90,6% dengan nilai mAP rata-rata 97,3%. Angka ini lebih tinggi dibandingkan beberapa penelitian terdahulu yang menggunakan CNN konvensional, yang rata-rata hanya menghasilkan akurasi 80–85%.

Kelebihan YOLOv5 terletak pada kemampuannya melakukan deteksi objek secara real-time dengan tingkat akurasi yang tetap tinggi. Hal ini sangat relevan jika sistem nantinya diimplementasikan pada aplikasi mobile untuk membantu petani mendiagnosis penyakit jambu biji langsung di kebun.

Namun demikian, penelitian ini masih memiliki keterbatasan. Misalnya, jumlah dataset yang digunakan relatif kecil (600 citra) dan belum mencakup seluruh variasi kondisi lapangan, seperti pencahayaan ekstrem atau gejala penyakit pada tahap awal. Hal ini berdampak pada masih adanya kesalahan klasifikasi, terutama pada kelas Styler and Root yang memiliki tingkat akurasi paling rendah dibandingkan kelas lainnya.

Untuk penelitian selanjutnya, disarankan agar dataset diperluas dengan variasi kondisi pencahayaan, sudut pengambilan gambar, serta tahap perkembangan penyakit. Selain itu, pengujian model pada perangkat mobile berbasis Android atau iOS juga penting dilakukan untuk memastikan sistem benar-benar dapat digunakan di lapangan oleh petani.



#### 4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan mengenai klasifikasi penyakit jambu biji menggunakan algoritma YOLOv5, dapat ditarik beberapa kesimpulan penting sebagai berikut:

1. Model YOLOv5 terbukti efektif untuk klasifikasi penyakit jambu biji. Penelitian ini berhasil membangun sistem deteksi penyakit jambu biji yang mampu bekerja secara real-time. Model dilatih menggunakan dataset berjumlah 600 citra yang mencakup tiga jenis penyakit utama, yaitu *Phytophthora*, *Scab*, dan *Styler and Root*.
2. Kinerja model sangat baik dengan nilai evaluasi tinggi. Model mencapai rata-rata precision 97,2%, recall 97,1%, mAP 97,3%, dan akurasi 90,6%. Confusion Matrix menunjukkan sebagian besar citra berhasil diklasifikasikan dengan benar, dengan kesalahan klasifikasi hanya terjadi pada beberapa kasus tertentu. Kurva evaluasi (precision, recall, dan F1-confidence) juga memperlihatkan kestabilan performa model pada berbagai nilai ambang *confidence*.
3. Potensi implementasi lapangan sangat tinggi. Dengan kemampuan deteksi cepat dan akurat, sistem ini berpotensi diintegrasikan ke dalam aplikasi mobile untuk mendukung petani dalam mendiagnosis penyakit jambu biji secara langsung di kebun. Hal ini dapat membantu petani mengambil keputusan penanganan lebih cepat, sehingga mengurangi risiko kerugian akibat penyakit.

#### DAFTAR PUSTAKA

- Fadhilah, A., Susanti, S., & Gultom, T. (2018). Karakterisasi Tanaman Jambu Biji (*Psidium Guajava* L) Di Desa Namoriam Pancur Batu Kabupaten Deli Serdang Sumatera Utara. *Prosiding Seminar Nasional Biologi Dan Pembelajarannya*.
- Hidayah, M. N., Sthevanie, F., & Ramadhani, K. N. (2023). Deteksi Penggunaan Masker Pada Citra Menggunakan YOLOv5 Dengan CNN. *E-Proceeding of ENGINEERING*, 10(5), 4903–4908.
- Ilahiyah, S., & Nilogiri, A. (2018). Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *JUSTINDO (Jurnal Sistem Dan Teknologi Informasi Indonesia)*, 3(2), 49–56.
- Kurniawati, F., & Kumala, A. R. (2021). Fitonematoda pada Tanaman Jambu Biji [Phytonematodes on Guava Plant]. *Jurnal Fitopatologi Indonesia*, 17(4), 169–171. <https://doi.org/10.14692/jfi.17.4>.
- Maso, K., Sesay, A., Lee, S., Hargreaves, E., Belecanech, R., Nguyen, C., Dellinger, R., & Schorr, C. (2015). Fluid resuscitation in septic shock patients perceived at risk for volume overload. *Critical Care Medicine*, 43(12). <https://doi.org/10.1097/01.ccm.0000474893.34162.5c>
- Mira, M., Firgia, L., & Thomas, S. (2023). Deteksi Jenis Penyakit Dan Hama Pada Tanaman Jagung Menggunakan Arsitektur Spatial Pyramid Pooling Pada YOLOv5s. *Jurnal Riset Sistem Informasi Dan Teknik Informatika (JURASIK)*, 8(2), 452–459.
- Rachmawati, F., & Widhyaestoeti, D. (2020). Early Warning System Untuk Prediksi Tingkat Pelayanan Jalan di Jalur SSA Kota Bogor. *Krea-TIF*, 8(2), 9–18. <https://doi.org/10.32832/kreatif.v8i2.3433>
- Umar. (2021). Deteksi Penyakit Daun Pada Citra Daun Jambu Biji Menggunakan Segmentasi Warna. *Jurnal Teknik Informatika Dan Sistem Informasi*, 1(1), 23–30.