

## Implementasi Arsitektur YOLOv11 untuk Deteksi Penyakit Daun Tebu

Daniel <sup>1\*</sup>, Dedy Hermanto <sup>2</sup>

<sup>1\*,2</sup> Universitas Multi Data Palembang, Kota Palembang, Provinsi Sumatera Selatan, Indonesia.

### article info

#### Article history:

Received 17 December 2025

Received in revised form

20 January 2026

Accepted 1 February 2026

Available online July 2026.

#### Keywords:

YOLOv11; Sugarcane Leaf;

Deep Learning.

#### Kata Kunci:

YOLOv11; Daun Tebu; Deep

Learning.

### abstract

Sugarcane (*Saccharum officinarum* L.) plays an important role in the national sugar industry, but its productivity has declined due to leaf diseases such as mosaic, red rot, rust, and yellow leaf. Manual identification is often inefficient, especially for farmers in remote areas. This study proposes a YOLOv11 architecture for the detection and classification of sugarcane leaf diseases based on digital images, with performance analysis compared to previous deep learning models and the effect of image augmentation on accuracy. The dataset from the Sugarcane Leaf Disease Dataset on Kaggle includes 2,521 images with five classes (healthy, mosaic, red rot, rust, yellow). The data was processed through preprocessing, division (80% training, 10% validation, 10% testing), and augmentation (rotation, translation, flip). The results show an average precision of 97.2%, recall of 98.2%, mAP@0.5 of 98.8%, and mAP@0.5:0.95 of 95.5%, proving the effectiveness of YOLOv11 in accurate and fast detection.

### abstract

Tanaman tebu (*Saccharum officinarum* L.) berperan penting dalam industri gula nasional, tetapi produktivitasnya menurun akibat penyakit daun seperti mosaic, red rot, rust, dan yellow leaf. Identifikasi manual sering tidak efisien, terutama bagi petani di wilayah terpencil. Penelitian ini mengusulkan arsitektur YOLOv11 untuk deteksi dan klasifikasi penyakit daun tebu berbasis citra digital, dengan analisis performa dibandingkan model deep learning sebelumnya serta pengaruh augmentasi citra terhadap akurasi. Dataset dari Sugarcane Leaf Disease Dataset di Kaggle mencakup 2.521 citra dengan lima kelas (healthy, mosaic, red rot, rust, yellow). Data diproses melalui preprocessing, pembagian (80% pelatihan, 10% validasi, 10% pengujian), dan augmentasi (rotasi, translasi, flip). Hasil menunjukkan precision rata-rata 97,2%, recall 98,2%, mAP@0.5 98,8%, serta mAP@0.5:0.95 95,5%, membuktikan efektivitas YOLOv11 dalam deteksi akurat dan cepat.

\*Corresponding Author. Email: [daniel13dnz@mhs.mdp.ac.id](mailto:daniel13dnz@mhs.mdp.ac.id) <sup>1\*</sup>.

## 1. Pendahuluan

Tanaman tebu (*Saccharum officinarum* L.) memegang peranan penting dalam mendukung industri gula nasional, khususnya untuk memenuhi kebutuhan konsumsi gula di Indonesia (Simping Yuliatun, Mufidatul Ilmiah, Arinta Rury Puspitasari, 2023). Sebagai salah satu komoditas unggulan, tebu adalah bahan baku utama dalam pembuatan gula pasir (Chiatra & Sabita, 2025). Berdasarkan data Badan Pusat Statistik (BPS) 2023, Jawa Timur tercatat sebagai penghasil tebu terbesar di Indonesia, dengan total produksi mencapai 317.840 ton. Namun, meskipun memiliki peran strategis dalam perekonomian, sektor tebu menghadapi sejumlah tantangan dalam aspek produksi dan perdagangan. Pada 2023, ekspor gula Indonesia hanya mencapai 181.875 ton, menurun tajam dari 404.071 ton pada 2022 (Badan Pusat Statistik, 2023). Penurunan ini terkait langsung dengan menurunnya produksi tebu domestik yang pada gilirannya memengaruhi neraca perdagangan sektor pertanian. Kementerian Pertanian mencatat penurunan ekspor komoditas pertanian pada 2023 sebesar 5,06%, dari USD 13,11 miliar menjadi USD 12,46 miliar, yang sebagian besar disebabkan oleh menurunnya hasil produksi tebu.

Penurunan ini juga memengaruhi stabilitas pasokan gula nasional, yang sebagian besar disebabkan oleh faktor serangan penyakit pada tanaman tebu, khususnya pada daun yang mengurangi hasil panen dan kualitas tebu. Produktivitas tebu kerap terganggu oleh serangan berbagai penyakit yang menurunkan hasil panen secara signifikan. Deteksi dini terhadap penyakit tersebut dan penanganan yang cepat sangat diperlukan untuk menjaga kestabilan produksi. Salah satu aspek yang penting adalah kondisi daun tebu, karena penurunan fungsi fotosintesis yang disebabkan oleh penyakit pada daun sangat mempengaruhi produktivitas tanaman tebu itu sendiri (Amrulloh *et al.*, 2024). Penyakit seperti mosaik, red rot, rust, dan yellow leaf dapat menurunkan kualitas daun yang berimbas pada penurunan hasil panen (Daphal & Koli, 2024). Serangan penyakit ini tidak hanya merugikan petani tetapi juga pabrik gula yang bergantung pada pasokan tebu. Sebagai contoh, virus daun kuning tebu (*ScYLV*) menyebabkan penurunan hasil panen hingga 39–43% dan penurunan rendemen

(persentase kandungan gula) sekitar 30–34% (Bertasello *et al.*, 2023). Penyakit lain seperti bercak merah (*red rot*) dan mosaik (*mosaic*) juga berkontribusi terhadap penurunan produktivitas yang signifikan (Sakshi Srivastava *et al.*, 2020). Bahkan, penyakit karat (*rust*) dapat menyebabkan kerugian hingga 50% pada panen yang terinfeksi (Selvakumar & Viswanathan, 2019). Hal ini menegaskan bahwa penyakit daun tebu memiliki dampak yang besar terhadap produktivitas sektor pertanian. Tradisional, penyakit pada daun tebu diidentifikasi oleh ahli pertanian, namun cara ini tidak selalu efisien, khususnya bagi petani yang berada di daerah terpencil. Jarak yang jauh dari pusat layanan pertanian serta biaya konsultasi yang tinggi menyebabkan penanganan penyakit menjadi lambat, yang pada akhirnya berdampak pada keterlambatan respons terhadap ancaman hama atau penyakit (Wardiman *et al.*, 2024). Oleh karena itu, teknologi komputer dapat menjadi solusi efisien untuk mengatasi masalah tersebut. Dengan memanfaatkan teknologi *deep learning* dan *computer vision*, petani dapat melakukan deteksi dan klasifikasi penyakit tanaman secara lebih cepat dan akurat, tanpa bergantung pada tenaga ahli (Soeb *et al.*, 2023).


Teknik klasifikasi yang umum digunakan dalam *data mining* dapat digunakan untuk mengelompokkan jenis penyakit berdasarkan ciri-ciri yang teridentifikasi pada citra daun (Ikhwan & Aslami, 2020). Untuk deteksi penyakit pada tanaman, diperlukan algoritma deteksi objek yang andal. Salah satu algoritma yang banyak digunakan adalah YOLO (*You Only Look Once*), yang memproses gambar secara keseluruhan dalam satu waktu dan menggunakan jaringan saraf untuk memprediksi lokasi objek serta mengklasifikasikan objek tersebut (Bitra *et al.*, 2024). Penerapan YOLO telah terbukti efektif dalam mendeteksi penyakit pada berbagai tanaman. Sebagai contoh, YOLOv8 digunakan untuk mendeteksi penyakit daun kopi (Bitra *et al.*, 2024), YOLOv5 untuk penyakit daun apel (Liu & Li, 2024), dan YOLOv7 untuk penyakit daun tomat dengan akurasi yang tinggi (Umar *et al.*, 2024). Studi lainnya menunjukkan bahwa YOLOv8 dengan *transfer learning* berhasil digunakan untuk mendeteksi penyakit pada daun jagung (Yang *et al.*, 2024). Berdasarkan hasil-hasil tersebut, dapat disimpulkan bahwa YOLO merupakan algoritma yang sangat tepat karena kombinasi kecepatan, akurasi, dan fleksibilitasnya dalam menyesuaikan dengan berbagai

jenis tanaman dan kondisi lingkungan, menjadikannya alat yang efektif dalam inovasi pertanian modern. Penelitian ini memanfaatkan dataset "Sugarcane Leaf Disease Dataset" dari Kaggle yang berisi 2.512 gambar daun tebu dengan enam kategori: sehat (*healthy*), mosaik (*mosaic*), red rot (*red rot*), rust (*rust*), dan yellow leaf (*yellow leaf*). Dataset ini diperluas menggunakan teknik augmentasi gambar, termasuk rotasi, zoom, flip horizontal, dan flip vertikal, untuk meningkatkan performa model *deep learning* dalam mendeteksi penyakit. Dataset ini mendukung penerapan model *YOLOv11* untuk deteksi penyakit daun tebu, sehingga memberikan kontribusi penting dalam implementasi pertanian presisi, di mana petani dapat mengidentifikasi dan menangani penyakit dengan lebih cepat dan efisien. Penelitian ini bertujuan untuk mencapai beberapa tujuan spesifik, yaitu:

- 1) Mengimplementasikan algoritma *YOLOv11* untuk deteksi penyakit pada daun tebu.
- 2) Menganalisis kinerja *YOLOv11* dalam deteksi penyakit daun tebu dan membandingkannya dengan model *deep learning* lainnya.
- 3) Mengukur pengaruh teknik augmentasi gambar terhadap peningkatan akurasi model *YOLOv11*.
- 4) Membantu petani dalam melakukan deteksi dini penyakit daun tebu secara efisien tanpa ketergantungan pada tenaga ahli.
- 5) Memberikan kontribusi ilmiah dalam bidang *computer vision* dan *deep learning*, serta menjadi referensi untuk penelitian selanjutnya.
- 6) Menambah literatur mengenai efektivitas teknik augmentasi dan mendukung pengembangan aplikasi berbasis *AI* untuk pertanian presisi, guna meningkatkan kualitas dan produktivitas tanaman tebu.

## 2. Metodologi Penelitian

Dalam pelaksanaan penelitian ini, diterapkan perancangan metode untuk meminimalisir kesalahan dalam proses penelitian. Tahapan metodologi penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Metodologi Penelitian

### Studi Literatur

Pada tahap studi literatur peneliti mengumpulkan berbagai referensi dari jurnal ilmiah dan beberapa penelitian terkait yang berkaitan dengan judul penelitian, yaitu "Implementasi Arsitektur *YOLOv11* Untuk Deteksi Penyakit Daun Tebu".

### Pengumpulan Dataset


Pada tahap ini, dilakukan proses pengumpulan dataset berupa dataset gambar daun tebu diambil dari dataset yang bersifat publik di Kaggle dengan nama "Sugarcane Leaf Disease Dataset" (<https://www.kaggle.com/datasets/nirmalsankalana/sugarcane-leaf-disease-dataset>). Dataset ini berisi 2.521 gambar yang dibagi menjadi 5 kategori yaitu *healthy*, *mosaic*, *red rot*, *rust*, dan *yellow*. Data tersebut dibagi menjadi 3 bagian yaitu 80% untuk melatih 2.017 data, 10% untuk validasi dengan total 252 data, 10% untuk pengujian dengan total 252 data, dan pembagian dataset dapat dilihat pada Tabel 1.

Tabel 1. Pembagian Dataset

| No    | Kelas   | Train | Validation | Test | Total |
|-------|---------|-------|------------|------|-------|
| 1     | Healthy | 418   | 52         | 52   | 522   |
| 2     | Mosaic  | 370   | 46         | 46   | 462   |
| 3     | Red Rot | 414   | 52         | 52   | 518   |
| 4     | Rust    | 412   | 51         | 51   | 514   |
| 5     | Yellow  | 403   | 51         | 51   | 505   |
| Total |         | 2.017 | 252        | 252  | 2.521 |

### Perancangan

Pada tahapan ini dilakukan beberapa tahapan yang dilakukan dalam perancangan antara lain, *input dataset*, *image pre-processing*, *split dataset* yang dibagi menjadi 3 bagian yakni, data *training*, data *validation*, dan data *testing*. Pada data *training* dilakukan augmentasi data dan di *train* dan di validasi. Setelah data dilatih dilakukan evaluasi model untuk mengetahui hasil performa dari model yang dimana sistem perancangan model dapat dilihat dari Gambar 2.



Gambar 2. Skema Perancangan Model YOLOv11

#### 1) Input Dataset

Pada awal perencanaan dilakukan *input dataset* yang diperoleh dari platform kaggle yang berjudul "Sugarcane Leaf Disease Dataset" dengan total 2.521 data gambar yang dibagi menjadi 5 kategori yakni, *healthy*, *mosaic*, *red rot*, *rust*, dan *yellow*.

#### 2) Image Pre-processing

Pada tahap *image pre-processing*, seluruh citra pada dataset terlebih dahulu melalui tahap pra-pemrosesan berupa *resize* gambar. Proses ini

bertujuan untuk menyamakan ukuran citra menjadi 640x640 yang merupakan *default* dari citra *input* pada algoritma YOLO (Hussain, 2023).

#### 3) Split Dataset

Setelah proses *resize*, dataset dibagi ke dalam tiga bagian menggunakan metode *split dataset*. Pembagian dilakukan dengan proporsi 80% untuk data *training*, 10% untuk data validasi, dan 10% untuk data *testing*. Data *training* digunakan sebagai data utama untuk melatih model, data validasi berfungsi untuk memantau performa model selama proses pelatihan, sedangkan data testing digunakan untuk menguji performa akhir model secara objektif.

#### 4) Augmentasi Data

Setelah data di bagi, data *training* akan diperkuat dengan proses augmentasi data seperti rotasi, translasi, *flip*, dan *zoom* dengan tujuan untuk memperbanyak variasi data model agar tidak menghafal pola tertentu melainkan dapat mendeteksi gambar dengan pengambilan gambar baru yang tidak terdapat pada dataset.

#### 5) Train dan Validation

Selanjutnya dilakukan tahap *training* menggunakan algoritma YOLOv11. Pada tahap ini, model dilatih untuk mengenali ciri-ciri daun tebu yang sehat maupun yang terinfeksi penyakit. Model akan belajar dari pola, tekstur, dan perbedaan visual yang ada pada dataset hasil augmentasi. Selama proses pelatihan berlangsung, data validasi digunakan untuk mengevaluasi performa model secara berkala. Pada

#### 6) Evaluasi Model

Tahap berikutnya dilakukan evaluasi model YOLOv11 untuk menilai tingkat akurasi dan efektivitas dari model dalam mendeteksi dan mengklasifikasi penyakit daun tebu dengan menggunakan beberapa metrik yakni, *precision*, *recall*, *f1-score*, serta *mean Average Precision (mAP)*.

## 7) Implementasi

Pada tahapan ini dilakukan implementasi dengan melatih model YOLOv11 menggunakan data latih yang sudah melalui data *pra-preprocessing*. Proses pelatihan dijalankan menggunakan *framework Ultralytics YOLO* dan bahasa *python*. Beberapa parameter yang digunakan dalam pelatihan antara lain jumlah 10 *epoch*, ukuran 16 *batch*, 100 *learning rate*, dan *optimizer* SGD.

## 8) Pengujian

Pada tahapan ini, sistem yang telah dibuat sebelumnya akan melakukan uji coba terhadap data uji.

Setelah tahapan uji coba, hasil pengujian dihitung untuk mendapatkan tingkat keberhasilan metode yang digunakan dengan *Confusion Matrix* dalam menghitung nilai *precision*, *recall*, dan *F1-Score* yang dapat dilihat pada Persamaan (1), (2), dan (3).

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (2)$$

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (3)$$

Keterangan:

TP: Jumlah data positif yang terklasifikasi dengan benar oleh sistem

TN: Jumlah data negatif yang terklasifikasi dengan benar oleh sistem

FN: Jumlah data negatif yang terklasifikasi dengan salah oleh sistem

FP: Jumlah data positif yang terklasifikasi dengan salah oleh sistem

Selain *confusion matrix* dilakukan juga pengujian untuk melakukan deteksi dengan melihat *Average Precision (AP)* serta *mean Average Precision (mAP)* untuk mengukur seberapa baik model dalam melakukan klasifikasi jenis penyakit daun tebu yang dapat dilihat pada Persamaan (4) dan (5).

$$AP = \frac{Precision+Recall}{2} \quad (4)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (5)$$

### 3. Hasil dan Pembahasan

#### Hasil

##### Pengumpulan Data

Pada tahap ini, dilakukan proses pengumpulan *dataset* berupa *dataset* gambar daun tebu diambil dari *dataset* yang bersifat publik di Kaggle dengan nama “*Sugarcane Leaf Disease Dataset*” (<https://www.kaggle.com/datasets/nimalsankalana/sugarcane-leaf-disease-dataset>). *Dataset* ini berisi 2.521 gambar yang dibagi menjadi 5 kategori yaitu *healthy*, *mosaic*, *red rot*, *rust*, dan *yellow*. Data tersebut dibagi menjadi 3 bagian yaitu 80% untuk melatih 2.017 data, 10% untuk validasi dengan total 252 data, 10% untuk pengujian dengan total 252 data. Dengan karakteristik penyakit daun tebu dijelaskan pada Tabel 2.

Tabel 2. Karakteristik Penyakit Daun Tebu


| Kelas          | Keterangan                                                                                                                                                                       | Gambar Daun                                                                          |
|----------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------|
| <i>Healthy</i> | Daun berwarna hijau merata, permukaan halus, tanpa bercak, garis pucat, atau perubahan warna. Tidak terlihat gejala infeksi jamur, virus, atau bakteri. Dengan total 522 gambar. |  |

|                |                                                                                                                                                                                                                                    |
|----------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <i>Mosaic</i>  | Daun menunjukkan tanda berupa bercak hijau muda–kuning tidak merata, membentuk corak mosaik. Warna hijau terlihat tidak konsisten, dengan area pucat memanjang di sepanjang tulang daun. Dengan total 462 gambar.                  |
| <i>Red Rot</i> | Daun mengalami perubahan warna dengan munculnya garis atau pita memanjang berwarna coklat kemerahan di bagian tengah atau sisi daun. Sering diikuti dengan pengeringan jaringan di sekitar area tersebut. Dengan total 518 gambar. |
| <i>Rust</i>    | Daun memiliki bintik-bintik kecil berwarna coklat tua kehitaman yang tersebar, biasanya disebabkan spora jamur. Bercak cenderung berbentuk bulat kecil dan muncul dalam jumlah banyak di permukaan daun. Dengan total 514 gambar.  |
| <i>Yellow</i>  | Daun mengalami klorosis, ditandai dengan warna kuning dominan terutama di sisi kanan-kiri tulang daun. Hijau hanya tersisa sedikit di bagian tengah. Dengan total 505 gambar.                                                      |




### Pre-Processing Data

Pada tahap *image pre-processing*, seluruh citra pada dataset terlebih dahulu melalui tahap pra-pemrosesan berupa *resize* gambar. Proses ini bertujuan untuk menyamakan ukuran citra menjadi 640x640 yang merupakan *default* dari citra *input* pada algoritma YOLO. Kemudian setiap gambar akan diberikan *boundary box* pada bagian penyakitnya, tujuannya agar model mampu mengenali ciri penyakit pada daun teh. Pemberian *labeling boundary box* menggunakan aplikasi *website* Roboflow yang dilakukan secara manual.




Gambar 3. Proses Labeling Daun Tebu *Healthy*

Pada Gambar 3 dapat dilihat contoh proses labeling Daun Tebu *Mosaic* yang menunjukkan tanda berupa bercak hijau muda–kuning tidak merata, membentuk corak mosaik.




Gambar 4. Proses Labeling Daun Tebu *Red Rot*

Pada Gambar 4 dapat dilihat contoh proses labeling Daun Tebu *Red Rot* yang dapat dilihat perubahan warna dengan munculnya garis atau pita memanjang berwarna coklat kemerahan di bagian tengah atau sisi daun.

Gambar 5. Proses Labeling Daun Tebu *Rust*

Pada Gambar 5 dapat dilihat contoh proses labeling Daun Tebu *Rust* yang dapat dilihat bintang-bintang kecil berwarna coklat tua kehitaman yang tersebar, biasanya disebabkan spora jamur.

Gambar 6. Proses Labeling Daun Tebu *Yellow*

Pada Gambar 6 dapat dilihat contoh proses labeling Daun Tebu *Yellow* yang ditandai dengan warna kuning dominan terutama di sisi kanan-kiri tulang daun. Hijau hanya tersisa sedikit di bagian tengah.

### Pembagian Data

Setelah dilakukan tahapan pre-processing, sebanyak 2.521 data gambar dibagi menjadi Data tersebut dibagi menjadi 3 bagian yaitu 80% untuk melatih 2.017 data, 10% untuk validasi dengan total 252 data, 10% untuk pengujian dengan total 252 data, dan pembagian dataset dapat dilihat pada Tabel 3.

Tabel 3. Pembagian Dataset

| No    | Kelas   | Train | Validation | Test | Total |
|-------|---------|-------|------------|------|-------|
| 1     | Healthy | 418   | 52         | 52   | 522   |
| 2     | Mosaic  | 370   | 46         | 46   | 462   |
| 3     | Red Rot | 414   | 52         | 52   | 518   |
| 4     | Rust    | 412   | 51         | 51   | 514   |
| 5     | Yellow  | 403   | 51         | 51   | 505   |
| Total |         | 2.017 | 252        | 252  | 2.521 |

### Augmentasi dan Parameter

Dilakukan augmentasi data pada data train. Pada augmentasi data yang dilakukan rotasi, translasi, skala, dan pembalikan pada data *training set* dapat dilihat dari Tabel 4.

Tabel 4. Augmentasi Dataset

| Keterangan                         | Nilai |
|------------------------------------|-------|
| <i>degrees</i>                     | 10    |
| <i>translate</i>                   | 0.25  |
| <i>scale</i>                       | 1.0   |
| <i>flipud</i> (pembalikan sumbu x) | 0.5   |
| <i>flplr</i> (pembalikan sumbu y)  | 0.5   |

Selain itu dilakukan juga penetapan parameter yang digunakan pada model yang dapat dilihat pada Tabel 5.

Tabel 5. Parameter Yang Digunakan

| Nama                 | Nilai |
|----------------------|-------|
| Epoch                | 100   |
| <i>Batch Size</i>    | 16    |
| <i>Image Size</i>    | 640   |
| <i>Optimizer</i>     | SGD   |
| <i>Learning Rate</i> | 0.001 |

Berdasarkan Tabel 5 Parameter yang digunakan pada *training* 100 epoch yang sudah dilakukan menggunakan *batch size* 16 karena mampu menyeimbangkan efisiensi komputasi dan penggunaan memori, serta memastikan proses pelatihan berjalan stabil dan efektif (Sharma *et al*, 2024). *image size* 640 digunakan untuk menyamakan ukuran citra menjadi 640x640 yang merupakan *default* dari citra *input* pada algoritma YOLO (Hussain, 2023), *optimizer* SGD digunakan karena mampu memberikan hasil yang stabil dan konsisten dalam proses pelatihan model deteksi objek (Moraes *et al*, 2025), dan *learning rate* 0.001 dipilih karena literatur menunjukkan nilai ini menjadi titik keseimbangan yang baik antara kecepatan konvergensi dan kestabilan pelatihan yang memungkinkan pembaruan bobot yang cukup besar untuk belajar efektif namun tidak terlalu agresif hingga melewati minimum loss (Peng, 2024).

### Pengujian

Pengujian dilakukan menggunakan data uji yang telah dipisahkan sebelumnya. Proses evaluasi memanfaatkan dua metode utama, yaitu Confusion

Matrix untuk menghitung Precision dan Recall (mAP) meliputi mAP@0.5 dan mAP@0.5:0.95—sekaligus mengidentifikasi pola kesalahan seperti False Positive dan False Negative. Selain itu, model dievaluasi menggunakan mean Average Precision berdasarkan analisis kurva Precision–Recall pada setiap kelas.


Tabel 6. Hasil Train Per Epoch

| <i>epoch</i> | <i>metrics/precision</i> | <i>metrics/Recall</i> | <i>metrics/mAP50</i> | <i>metrics/mAP50-95</i> |
|--------------|--------------------------|-----------------------|----------------------|-------------------------|
| 1            | 0.275                    | 0.57                  | 0.333                | 0.255                   |
| 2            | 0.538                    | 0.661                 | 0.597                | 0.398                   |
| 3            | 0.629                    | 0.765                 | 0.746                | 0.491                   |
| 4            | 0.765                    | 0.771                 | 0.82                 | 0.578                   |
| 5            | 0.831                    | 0.878                 | 0.919                | 0.678                   |
| 6            | 0.779                    | 0.877                 | 0.891                | 0.683                   |
| 7            | 0.865                    | 0.851                 | 0.905                | 0.707                   |
| 8            | 0.8                      | 0.843                 | 0.9                  | 0.708                   |
| 9            | 0.925                    | 0.844                 | 0.954                | 0.793                   |
| 10           | 0.917                    | 0.882                 | 0.945                | 0.766                   |
| 11           | 0.916                    | 0.853                 | 0.956                | 0.779                   |
| 12           | 0.933                    | 0.911                 | 0.959                | 0.804                   |
| 13           | 0.942                    | 0.928                 | 0.971                | 0.82                    |
| 14           | 0.919                    | 0.915                 | 0.955                | 0.821                   |
| 15           | 0.919                    | 0.91                  | 0.97                 | 0.828                   |
| 16           | 0.951                    | 0.907                 | 0.959                | 0.817                   |
| 17           | 0.895                    | 0.916                 | 0.945                | 0.799                   |
| 18           | 0.934                    | 0.925                 | 0.955                | 0.825                   |
| 19           | 0.948                    | 0.902                 | 0.955                | 0.818                   |
| 20           | 0.916                    | 0.907                 | 0.956                | 0.824                   |
| 21           | 0.938                    | 0.949                 | 0.97                 | 0.836                   |
| 22           | 0.92                     | 0.915                 | 0.959                | 0.821                   |
| 23           | 0.921                    | 0.948                 | 0.964                | 0.827                   |
| 24           | 0.921                    | 0.9                   | 0.958                | 0.81                    |
| 25           | 0.896                    | 0.94                  | 0.965                | 0.843                   |
| 26           | 0.92                     | 0.901                 | 0.957                | 0.834                   |
| 27           | 0.944                    | 0.902                 | 0.958                | 0.829                   |
| 28           | 0.921                    | 0.94                  | 0.973                | 0.847                   |
| 29           | 0.948                    | 0.932                 | 0.964                | 0.846                   |
| 30           | 0.95                     | 0.927                 | 0.976                | 0.85                    |
| 31           | 0.925                    | 0.931                 | 0.954                | 0.836                   |
| 32           | 0.939                    | 0.921                 | 0.97                 | 0.864                   |
| 33           | 0.94                     | 0.909                 | 0.965                | 0.843                   |
| 34           | 0.882                    | 0.928                 | 0.955                | 0.838                   |
| 35           | 0.945                    | 0.93                  | 0.978                | 0.849                   |
| 36           | 0.946                    | 0.93                  | 0.961                | 0.838                   |
| 37           | 0.937                    | 0.943                 | 0.973                | 0.839                   |
| 38           | 0.94                     | 0.922                 | 0.968                | 0.845                   |
| 39           | 0.928                    | 0.945                 | 0.967                | 0.856                   |
| 40           | 0.927                    | 0.952                 | 0.969                | 0.855                   |

|    |       |       |       |       |
|----|-------|-------|-------|-------|
| 41 | 0.919 | 0.924 | 0.949 | 0.839 |
| 42 | 0.938 | 0.953 | 0.975 | 0.855 |
| 43 | 0.946 | 0.949 | 0.967 | 0.857 |
| 44 | 0.948 | 0.937 | 0.974 | 0.85  |
| 45 | 0.948 | 0.953 | 0.972 | 0.857 |
| 46 | 0.952 | 0.958 | 0.976 | 0.861 |
| 47 | 0.96  | 0.946 | 0.971 | 0.858 |
| 48 | 0.961 | 0.933 | 0.973 | 0.87  |
| 49 | 0.964 | 0.938 | 0.973 | 0.866 |
| 50 | 0.946 | 0.936 | 0.968 | 0.865 |
| 51 | 0.971 | 0.946 | 0.977 | 0.868 |
| 52 | 0.967 | 0.934 | 0.98  | 0.877 |
| 53 | 0.956 | 0.935 | 0.968 | 0.87  |
| 54 | 0.953 | 0.942 | 0.973 | 0.866 |
| 55 | 0.937 | 0.949 | 0.971 | 0.859 |
| 56 | 0.958 | 0.965 | 0.98  | 0.868 |
| 57 | 0.958 | 0.964 | 0.982 | 0.874 |
| 58 | 0.964 | 0.946 | 0.972 | 0.871 |
| 59 | 0.96  | 0.936 | 0.972 | 0.865 |
| 60 | 0.936 | 0.95  | 0.981 | 0.882 |
| 61 | 0.946 | 0.936 | 0.961 | 0.852 |
| 62 | 0.946 | 0.935 | 0.959 | 0.846 |
| 63 | 0.963 | 0.931 | 0.976 | 0.87  |
| 64 | 0.953 | 0.957 | 0.974 | 0.861 |
| 65 | 0.947 | 0.941 | 0.972 | 0.868 |
| 66 | 0.935 | 0.966 | 0.973 | 0.866 |
| 67 | 0.941 | 0.945 | 0.969 | 0.864 |
| 68 | 0.968 | 0.919 | 0.978 | 0.879 |
| 69 | 0.959 | 0.953 | 0.976 | 0.868 |
| 70 | 0.953 | 0.963 | 0.972 | 0.869 |
| 71 | 0.966 | 0.943 | 0.972 | 0.872 |
| 72 | 0.968 | 0.933 | 0.975 | 0.867 |
| 73 | 0.958 | 0.964 | 0.983 | 0.874 |
| 74 | 0.975 | 0.95  | 0.982 | 0.882 |
| 75 | 0.967 | 0.952 | 0.972 | 0.869 |
| 76 | 0.943 | 0.971 | 0.973 | 0.871 |
| 77 | 0.962 | 0.955 | 0.978 | 0.886 |
| 78 | 0.948 | 0.959 | 0.971 | 0.874 |
| 79 | 0.971 | 0.954 | 0.983 | 0.886 |
| 80 | 0.96  | 0.962 | 0.977 | 0.882 |
| 81 | 0.964 | 0.963 | 0.979 | 0.884 |
| 82 | 0.959 | 0.969 | 0.981 | 0.889 |
| 83 | 0.968 | 0.941 | 0.979 | 0.881 |
| 84 | 0.948 | 0.956 | 0.978 | 0.878 |
| 85 | 0.959 | 0.943 | 0.976 | 0.88  |
| 86 | 0.953 | 0.938 | 0.979 | 0.884 |
| 87 | 0.934 | 0.962 | 0.98  | 0.886 |

|     |       |       |       |       |
|-----|-------|-------|-------|-------|
| 88  | 0.961 | 0.96  | 0.98  | 0.889 |
| 89  | 0.965 | 0.963 | 0.978 | 0.881 |
| 90  | 0.96  | 0.959 | 0.979 | 0.883 |
| 91  | 0.951 | 0.943 | 0.974 | 0.878 |
| 92  | 0.957 | 0.945 | 0.978 | 0.881 |
| 93  | 0.944 | 0.971 | 0.978 | 0.88  |
| 94  | 0.964 | 0.945 | 0.979 | 0.884 |
| 95  | 0.961 | 0.94  | 0.979 | 0.886 |
| 96  | 0.936 | 0.96  | 0.979 | 0.885 |
| 97  | 0.943 | 0.962 | 0.981 | 0.888 |
| 98  | 0.979 | 0.929 | 0.983 | 0.888 |
| 99  | 0.963 | 0.937 | 0.982 | 0.887 |
| 100 | 0.944 | 0.963 | 0.981 | 0.886 |

Berdasarkan hasil pengujian menggunakan epoch 100 yang dapat dilihat pada Tabel 6 hasil menunjukkan performa yang konsisten dan cukup tinggi dengan nilai Precision rata-rata sebesar 96,2%; Recall rata-rata sebesar 95,8%; mAP50 rata-rata sebesar 98%; mAP 50-95 rata-rata sebesar 88,9%. Dengan hasil yang didapat dengan menggunakan 100 epoch model mampu mempelajari penyakit daun tebu dengan baik.



Gambar 7. Grafik Hasil Train

Berdasarkan grafik hasil train dari Gambar 7 tersebut, setelah dilakukan *training* 100 epoch, model menunjukkan performa yang cukup tinggi dan stabil. Pada grafik train/box\_loss, train/cls\_loss, dan train/dfl\_loss terlihat penurunan nilai yang stabil di setiap *epoch*, menandakan bahwa model berhasil mempelajari pola objek, jenis kelas, serta posisi *bounding box* dari dataset yang digunakan. Sementara itu pada grafik val/box\_loss, val/cls\_loss, dan val/dfl\_loss juga terjadi penurunan nilai loss yang baik, meskipun terdapat fluktuasi pada awal proses *training* dan *validation*. Grafik matriks *recall*, *precision*, *mAP@50*, dan *mAP@50-95* menunjukkan bahwa model berhasil mempelajari dan mendeteksi penyakit daun tebu dengan baik yang ditandai dengan nilai *mAP* mendekati 100%. Hal ini menunjukkan bahwa model dapat memprediksi kelas dari data baru yang belum pernah dilihat sebelumnya. Grafik hasil training yang terdiri dari *box\_loss*, *cls\_loss*, *dfl\_loss*, *precision*, dan *recall* dapat dilihat di Gambar 7.


Tabel 7. Hasil Pengujian

| Kelas     | Precision | Recall | mAP@0.5 | mAP@0.5:0.95 |
|-----------|-----------|--------|---------|--------------|
| Healthy   | 98,1%     | 96,6%  | 98,4%   | 90,4%        |
| Mosaic    | 89,2%     | 97,2%  | 97,7%   | 88,9%        |
| Red Rot   | 98,1%     | 94,5%  | 97,7%   | 81,2%        |
| Rust      | 98,5%     | 93,3%  | 97,3%   | 92,4%        |
| Yellow    | 97,2%     | 97,6%  | 98,8%   | 91,7%        |
| Rata-Rata | 96,2%     | 95,8%  | 98%     | 88,9%        |

Berdasarkan hasil pengujian pada Tabel 7 menunjukkan bahwa model memberikan performa yang sangat stabil di hampir semua kelas. Secara keseluruhan, nilai *precision* berada pada kisaran tinggi


dengan rata-rata 97,2%, sementara *recall* mencapai rata-rata 98,2%. Nilai *mAP@0.5* juga terlihat sangat kuat di angka 98,8%, dan *mAP@0.5:0.95* berada pada 95,5%. Jika dilihat lebih dalam, kelas *Healthy* menjadi

kategori yang paling konsisten karena ciri visualnya yang relatif mudah dikenali. Sebaliknya, beberapa kelas penyakit seperti *Mosaic* dan *Red Rot* sedikit lebih menantang. Pada *Mosaic*, *precision* yang lebih rendah menunjukkan bahwa model masih sesekali keliru mengira kelas lain sebagai *Mosaic*, kemungkinan akibat pola bercak yang mirip. Untuk *Red Rot* dan *Rust*, *recall* yang lebih rendah mengindikasikan bahwa sebagian citra tidak terdeteksi dengan baik, terutama karena kemiripan tekstur dan warna di antara keduanya. Meski begitu, performa rata-rata tetap berada pada level yang sangat kompetitif. Hasil ini menegaskan bahwa arsitektur YOLOv11 mampu bekerja dengan sangat efektif dalam mendeteksi tiap kelas penyakit daun tebu, meskipun masih ada tantangan pada kelas dengan karakteristik visual yang saling berdekatan. Hasil *confusion matrix* dapat dilihat pada Gambar 8.



Gambar 8. Confusion Matrix

Hasil implementasi model YOLOv11 dalam mendeteksi penyakit daun tebu pada penelitian ini dapat dilihat pada Gambar 9.



Gambar 9. Hasil Deteksi Model

## Pembahasan

Secara keseluruhan, hasil pengujian menunjukkan bahwa model berhasil mempertahankan keseimbangan yang baik antara kemampuan mengenali objek dengan akurat dan menghindari kesalahan deteksi. Tingginya nilai *precision* mengindikasikan bahwa model jarang salah dalam memberikan label pada citra yang tidak termasuk dalam kelas tersebut. Di sisi lain, tingginya nilai *recall* menunjukkan bahwa sebagian besar objek yang seharusnya terdeteksi oleh model tidak terlewatkan. Hal ini sejalan dengan temuan dari Bitra *et al.* (2024), yang mengemukakan bahwa kombinasi *precision* dan *recall* yang tinggi menjadi indikator utama dalam keberhasilan model deteksi penyakit pada tanaman. Nilai *mAP@0.5* yang mendekati angka sempurna menguatkan bahwa proses deteksi berjalan sangat efektif. Ketika standar penilaian diperketat melalui *mAP@0.5:0.95*, akurasi dalam melokalisasi *bounding box* tetap terjaga dengan baik. Hal ini mendukung hasil penelitian Liu & Li (2024), yang menemukan bahwa *mAP* yang tinggi menunjukkan keandalan model dalam mendeteksi dan membatasi objek dengan presisi yang tinggi.

Pada *confusion matrix*, terlihat bahwa kelas "Healthy" relatif lebih mudah dikenali oleh model, karena pola teksturnya yang lebih seragam dan khas. Sebaliknya, pada kelas penyakit, beberapa faktor, seperti ukuran bercak yang sangat kecil, kesamaan warna gejala antar kelas, dan pencahayaan yang bervariasi, sering menyebabkan kebingungan pada model. Fenomena ini menyebabkan kesalahan deteksi yang muncul dalam bentuk *false negative* dan *false positive*, yang sejalan dengan temuan dari Umar *et al.* (2024), yang menunjukkan bahwa model sering kali mengalami kesulitan dalam membedakan antara kelas-kelas yang memiliki kemiripan visual yang tinggi. Kesalahan semacam ini menunjukkan tantangan yang harus dihadapi dalam pengembangan model deteksi penyakit tanaman, terutama dalam situasi dengan variasi gejala yang halus. Menurut Yang *et al.* (2024), variasi dalam gejala visual antar kelas penyakit memerlukan pengembangan teknik augmentasi data yang lebih beragam untuk meningkatkan kemampuan model dalam mengenali perbedaan yang lebih detail pada citra.

#### 4. Kesimpulan dan Saran

Berdasarkan rangkaian proses yang meliputi pengumpulan data, pelatihan model, dan evaluasi performa, penelitian ini membuktikan bahwa YOLOv11 mampu mendeteksi penyakit daun tebu dengan tingkat akurasi yang sangat tinggi. Hasil pengujian dengan 100 epoch menunjukkan nilai *precision* rata-rata sebesar 97,2%, sementara *recall* mencapai rata-rata 98,2%. Nilai *mAP@0.5* yang sangat baik, yaitu 98,8%, serta *mAP@0.5:0.95* yang mencapai 95,5%, menunjukkan bahwa model ini mampu mendeteksi penyakit daun tebu dengan sangat baik pada lima kelas klasifikasi: *healthy*, *mosaic*, *red rot*, *rust*, dan *yellow*. Pencapaian ini menegaskan efektivitas arsitektur YOLOv11 dalam deteksi penyakit tanaman yang akurat dan efisien. Beberapa saran untuk penelitian selanjutnya guna meningkatkan kualitas dan efektivitas model ini antara lain: pertama, disarankan untuk menambah jumlah serta variasi data, khususnya untuk kelas penyakit dengan gejala visual yang serupa. Hal ini akan meningkatkan kemampuan model dalam mengenali kondisi lapangan yang lebih beragam dan memperkuat generalisasi model terhadap berbagai variasi penyakit daun tebu. Kedua, teknik augmentasi yang lebih beragam, seperti penyesuaian warna, penghapusan sebagian area, atau kombinasi berbagai teknik augmentasi, dapat meningkatkan ketahanan model terhadap perubahan kondisi citra dan membantu model dalam mengenali pola yang lebih kompleks. Ketiga, untuk memperluas aplikasi model, perlu dilakukan pengujian pada citra dengan resolusi yang lebih rendah maupun lebih tinggi. Hal ini penting untuk mengetahui pengaruh ukuran input terhadap kecepatan deteksi dan efisiensi, khususnya ketika model diterapkan pada perangkat dengan spesifikasi terbatas.

#### 5. Daftar Pustaka

- Amrulloh, T. A., Sari, I. N., Padilah, B. N., & Tesa. (2024). Evaluasi augmentasi data pada deteksi penyakit daun tebu dengan YOLOv8. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(4), 7547–7552. <https://doi.org/10.36040/jati.v8i4.10267>.
- Bertasello, L. E. T., da Silva, M. F., Pinto, L. R., Nóbile, P. M., Carmo-Sousa, M., dos Anjos, I. A., Perecin, D., Spotti Lopes, J. R., & Gonçalves, M. C. (2023). Yellow leaf disease resistance and *Melanaphis sacchari* preference in commercial sugarcane cultivars. *Plants*, 12(17), 1–15. <https://doi.org/10.3390/plants12173079>.
- Bitra, M., Dewi, C., Wacana, K. S., & Tengah, J. (2024). Penggunaan YOLOv8 untuk deteksi penyakit daun kopi. *KESATRIA: Jurnal Penerapan Sistem Informasi (Komputer & Manajemen)*, 5(4), 1805–1813.
- Chiatra, S. D., & Sabita, H. (2025). Deteksi objek daun tebu dengan menggunakan metode klasifikasi pada machine learning. *Seminar Nasional Hasil Penelitian Dan Pengabdian Masyarakat 2025*, 113–124.
- Daphal, S. D., & Koli, S. M. (2024). Enhanced deep learning technique for sugarcane leaf disease classification and mobile application integration. *Heliyon*, 10(8), e29438. <https://doi.org/10.1016/j.heliyon.2024.e29438>.
- Ikhwan, A., & Aslami, N. (2020). Implementasi data mining untuk manajemen bantuan sosial menggunakan algoritma K-Means. *Jurnal Teknologi Informasi*, 4(2), 208–217. <https://doi.org/10.36294/jurti.v4i2.2103>.
- Liu, Z., & Li, X. (2024). An improved YOLOv5-based apple leaf disease detection method. *Scientific Reports*, 14(1), 1–13. <https://doi.org/10.1038/s41598-024-67924-8>.
- Peng, C. (2024). Comprehensive analysis of the impact of learning rate and dropout rate on the performance of convolutional neural networks on the CIFAR-10 dataset. *Applied and Computational Engineering*, 102(1), 183–192. <https://doi.org/10.54254/2755-2721/102/20241161>.
- Sakshi Srivastava, Prince Kumar, Noor Mohd, Anuj Singh, F. S. G. (2020). A novel deep learning

- framework approach for sugarcane disease detection. 1. <https://doi.org/10.1007/s42979-020-0094-9>.
- Selvakumar, R., & Viswanathan, R. (2019). Sugarcane rust: Changing disease dynamics and its management. *Journal of Sugarcane Research*, 9(2), 97. <https://doi.org/10.37580/jsr.2019.2.9.97-118>.
- Simping Yuliatun, Mufidatul Ilmiah, Arinta Rury Puspitasari, M. A. A. (2023). Pengaruh aplikasi pupuk silikat (BioSilAc dan SiAbate) pada pertumbuhan agronomi, serapan silika dan ketahanan terhadap serangan hama dan penyakit tanaman tebu varietas PSJK 922. *Indonesian Sugar Research Journal*, 3(1), 12–24.
- Soeb, M. J. A., Jubayer, M. F., Tarin, T. A., Al Mamun, M. R., Ruhad, F. M., Parven, A., Mubarak, N. M., Karri, S. L., & Meftaul, I. M. (2023). Tea leaf disease detection and identification based on YOLOv7 (YOLO-T). *Scientific Reports*, 13(1), 1–16. <https://doi.org/10.1038/s41598-023-33270-4>.
- Umar, M., Altaf, S., Ahmad, S., Mahmoud, H., Mohamed, A. S. N., & Ayub, R. (2024). Precision agriculture through deep learning: Tomato plant multiple diseases recognition with CNN and improved YOLOv7. *IEEE Access*, 12(February), 49167–49183. <https://doi.org/10.1109/ACCESS.2024.3383154>.
- Wardiman, B., Ardianto, Fitriyani, E., Herlyani, Ashar, J. R., & Panga, Nurhaya. J. (2024). *Pertanian keberlanjutan* (S. Sihotang & P. Hamzah, Eds.; 1st ed.). CV. Tohar Media.
- Yang, S., Yao, J., & Teng, G. (2024). Corn leaf spot disease recognition based on improved YOLOv8. *Agriculture (Switzerland)*, 14(5), 1–14. <https://doi.org/10.3390/agriculture14050666>
- Yunizar, S. R. I. F., & Pembimbing, D. (2024). Menggunakan algoritma convolutional neural network (CNN) dan support vector machine (SVM) [Undergraduate thesis, UPN Veteran Jatim]. <https://repository.upnjatim.ac.id/29200/>.