

Deteksi Penyakit Daun Teh Berdasarkan Citra Menggunakan Deep Learning

Andreas Saputra^{1*}, Dedy Hermanto²

^{1,2} Jurusan Informatika, Fakultas Ilmu Komputer dan Rekayasa, Universitas Multi Data Palembang, Kota Palembang, Provinsi Sumatera Selatan, Indonesia.

article info

Article history:

Received 30 September 2025

Received in revised form

10 October 2025

Accepted 20 October 2025

Available online April 2026.

Keywords:

Tea Leaves; Disease Detection; YOLOv11; Object Detection; mAP.

Kata Kunci:

Daun Teh; Deteksi Penyakit; YOLOv11; Deteksi Objek; mAP.

abstract

Tea plant (*Camellia sinensis*) originates from China and is one of the most widely consumed beverages in the world. Tea plants are vulnerable to leaf diseases such as Tea Leaf Blight, Tea Red Leaf Spot, and Tea Red Scab, which can reduce the quality and productivity of the harvest. Manual disease identification is still commonly used, but this method has many limitations, such as dependence on farmers' experience and inaccuracy in early detection. This study aims to apply the YOLOv11 algorithm as an object detection method to automatically, quickly, and accurately detect four classes of tea leaf conditions (three diseases and one healthy). The dataset used consists of 3,960 high-resolution tea leaf images that have undergone segmentation, augmentation, and normalization processes. The research was carried out through image preprocessing, YOLOv11 model training, and model performance evaluation using precision, recall, F1-score, and mean Average Precision (mAP) metrics. The results of tea leaf disease detection using YOLOv11 achieved 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%. This model can be used to help farmers identify tea leaf diseases more quickly and reduce the risk of crop yield losses.

abstrak

Tanaman teh (*Camelia Sinesis*) berasal dari Tiongkok dan merupakan salah satu minuman paling banyak dikonsumsi di dunia. Tanaman teh rentan terhadap serangan penyakit daun seperti Tea Leaf Blight, Tea Red Leaf Spot, dan Tea Red Scab, yang dapat menurunkan kualitas dan produktivitas hasil panen. Identifikasi penyakit secara manual masih umum digunakan, tetapi metode ini memiliki banyak keterbatasan, seperti ketergantungan pada pengalaman petani dan ketidaktepatan deteksi dini. Penelitian ini bertujuan untuk menerapkan algoritma YOLOv11 sebagai metode object detection dalam mendeteksi empat kelas kondisi daun teh (tiga penyakit dan satu sehat) secara otomatis, cepat, dan akurat. Dataset yang digunakan terdiri dari 3960 gambar daun teh beresolusi tinggi yang telah melalui proses segmentasi, augmentasi, dan normalisasi. Penelitian dilakukan dengan tahap pra-pemrosesan citra, pelatihan model YOLOv11, serta evaluasi kinerja model menggunakan metrik precision, recall, F1-score, dan mean Average Precision (mAP). Hasil dari penelitian deteksi penyakit daun teh dengan YOLOv11 memperoleh nilai rata-rata precision sebesar 97,2%, recall 98,2%, mAP@0.5 mencapai 98,8%, dan mAP@0.5:0.95 sebesar 95,5%. model ini dapat digunakan untuk membantu petani melakukan identifikasi penyakit daun teh lebih cepat dan mengurangi resiko kerugian hasil panen.

Corresponding Author. Email: saputraandreas05@mhs.mdp.ac.id ^{1}.

1. Pendahuluan

Teh (*Camellia sinensis*) merupakan salah satu komoditas perkebunan yang penting baik secara global maupun nasional. Konsumsi dunia mencapai 6,63 juta ton pada 2021 dan diproyeksikan meningkat menjadi 7,74 juta ton pada 2025, dengan nilai pasar global tumbuh rata-rata 6,75 persen per tahun sebagaimana dilaporkan oleh *Pusat Data dan Sistem Informasi Pertanian* (2024). Indonesia masih menjadi salah satu produsen utama, berada pada peringkat ketujuh dunia dengan kontribusi sekitar 1,99 persen terhadap total produksi. Teh juga menjadi sumber pendapatan bagi jutaan petani (Rimon *et al.*, 2025). Permintaan terhadap produk teh diperkirakan terus meningkat seiring pertumbuhan populasi dan perubahan pola konsumsi menuju gaya hidup sehat (Soeb *et al.*, 2023). Potensi tersebut dapat terhambat oleh penurunan produktivitas akibat penyakit daun. Gangguan seperti *Tea Leaf Blight*, *Tea Red Leaf Spot*, dan *Tea Red Scab* menimbulkan kerusakan jaringan daun, menghambat proses fotosintesis, dan berujung pada penurunan mutu dan jumlah panen (Rimon *et al.*, 2025).

Pada intensitas serangan yang berat, dampak ekonomi dapat dirasakan oleh petani maupun industri. Identifikasi penyakit daun teh di lapangan masih banyak mengandalkan pengamatan manual. Penilaian sangat bergantung pada kemampuan visual petani atau tenaga ahli sehingga rentan subjektif dan kurang memadai untuk diterapkan pada area perkebunan yang luas (Yasen *et al.*, 2023). Proses manual juga membutuhkan waktu lebih lama dan tidak selalu mampu mendukung kebutuhan deteksi dini, padahal keterlambatan identifikasi dapat memengaruhi efektivitas pengendalian penyakit. Pemanfaatan metode *Deep Learning* dan *Computer Vision* menjadi salah satu pendekatan yang ditawarkan untuk memperbaiki kondisi tersebut (Soeb *et al.*, 2023). Algoritma *object detection*, khususnya YOLO (*You Only Look Once*), telah terbukti efektif dalam penelitian deteksi penyakit tanaman lainnya, seperti daun kopi (Bitra & Dewi, 2023), daun cabai (Yasen *et al.*, 2023), daun durian (Putra *et al.*, 2024), dan padi (Krisdianto *et al.*, 2024). YOLO dikenal karena kecepatan inferensi dan akurasi yang tinggi dalam deteksi objek secara *real-time* (Jegham *et al.*, 2024). Pada kasus penyakit daun teh, salah satu

tantangan utama berada pada kebutuhan dataset berkualitas tinggi. Dataset beresolusi tinggi berisi 3960 citra daun teh telah tersedia, mencakup empat kelas kondisi daun dan diperoleh dari perkebunan di Moulvi Bazar, Sylhet, Bangladesh. Dataset tersebut telah melalui tahap segmentasi, normalisasi, pengurangan *noise*, dan *data augmentation* (Rimon *et al.*, 2025). Perkembangan arsitektur YOLO juga terus berlangsung. Versi terbaru seperti YOLOv11 menghadirkan peningkatan dalam akurasi, efisiensi komputasi, serta kemampuan mendeteksi objek kecil pada kondisi lingkungan yang beragam (Khanam & Hussain, 2024). Kemajuan tersebut membuka peluang lebih besar untuk meningkatkan performa deteksi penyakit daun teh secara otomatis. Penelitian ini diharapkan dapat mendukung penerapan pertanian presisi pada sektor teh, sehingga petani dan pengelola perkebunan dapat melakukan tindakan pengendalian dengan lebih cepat, tepat, dan berkelanjutan (Rimon *et al.*, 2025).

2. Metodologi Penelitian

Dalam pelaksanaan penelitian ini, tahapan yang dilakukan tersaji pada Gambar 1.



Gambar 1. Tahapan Metodologi Penelitian

Penelitian mengenai deteksi penyakit tanaman berbasis *deep learning* telah dilakukan dalam berbagai pendekatan, termasuk *Convolutional Neural Network*

(CNN) dan YOLO. Soeb *et al.* (2023) menggunakan YOLOv7 untuk mendeteksi lima jenis penyakit daun teh dan memperoleh mAP sebesar 98,2 persen serta $F1$ -score 0,965. Penelitian lain oleh Rimon *et al.* (2025) mengembangkan YOLOv8-RMDA dengan menambahkan modul *Residual Multiscale Dilated Attention* (RMDA) sehingga lebih mampu mendeteksi penyakit berukuran kecil, meskipun $mAP50$ yang dicapai masih berada pada angka 83,9 persen. Pendekatan CNN dengan *residual block* dan *global average pooling* juga telah diuji pada delapan kelas penyakit daun teh dan menghasilkan akurasi hingga 99 persen (Rahat *et al.*, 2025). Studi pada komoditas lain menunjukkan hasil serupa. Yassen *et al.* (2023) menerapkan YOLO untuk mendeteksi penyakit serta hama daun cabai dengan capaian mAP 75,1 persen, presisi 77,4 persen, dan *recall* 67,1 persen. Putra *et al.* (2024) menggunakan YOLOv8 pada daun durian dan memperoleh $mAP50$ sebesar 0,990 serta $mAP50-95$ sebesar 0,927.

Pada buah jeruk, Liao *et al.* (2025) memodifikasi YOLOv11 menjadi YOLO-MECD dengan penambahan modul *EMA attention* dan *CSPPC*, menghasilkan mAP sebesar 81,6 persen dan pengurangan parameter hingga 75,6 persen. Dalam ranah non-pertanian, Yudhi *et al.* (2025) menunjukkan bahwa YOLOv8 dan YOLOv11 dapat digunakan untuk mendeteksi pelanggaran aturan berpakaian mahasiswa secara *real-time*, dengan akurasi YOLOv11s mencapai 84,8 persen. Pada komoditas padi, penelitian oleh Krisdianto *et al.* (2024) melaporkan akurasi 77 persen dengan YOLOv5, sedangkan studi lain berbasis CNN mampu mencapai akurasi 95–98 persen. Penelitian terbaru menegaskan potensi YOLOv11 dalam sektor

pertanian. Lv *et al.* (2025) meneliti efisiensi *deployment* model deteksi penyakit daun kacang tanah berbasis YOLOX-Tiny pada perangkat *edge* seperti Jetson Nano dan melaporkan penurunan waktu inferensi hingga 55 persen. Wang *et al.* (2025) mengusulkan C2PSA-Enhanced YOLOv11 untuk mendeteksi penyakit kapas dan mencatat peningkatan $mAP50$ sebesar 8 persen serta $mAP50-95$ sebesar 10,5 persen. Pada deteksi penyakit daun apel, Gao *et al.* (2025) mengembangkan DMN-YOLO, yang meningkatkan presisi sebesar 5,5 persen, *recall* 3,4 persen, dan $mAP@50$ sebesar 5 persen dibandingkan model dasar. Teng *et al.* (2025) memperkenalkan YOLOv11-RD, sebuah varian ringan untuk deteksi penyakit padi, yang meningkatkan $mAP50-95$ sebesar 11,5 persen sekaligus mengurangi jumlah parameter hingga 4,58 juta. Penelitian lain oleh Gangadharan *et al.* (2025) menunjukkan bahwa YOLOv11 dapat digunakan untuk deteksi gulma dengan 31 kelas dan menghasilkan mAP 91,4 persen pada aplikasi web berbasis *Flask*. Sementara itu, Tang *et al.* (2025) mengembangkan YOLOv11-AIU untuk mendeteksi tingkat keparahan penyakit *early blight* pada tomat, dengan $mAP@50$ sebesar 94,1 persen dan $mAP@50-95$ sebesar 93,4 persen, serta dapat dijalankan pada perangkat *embedded*. Secara keseluruhan, berbagai penelitian tersebut menunjukkan bahwa model CNN unggul pada tugas klasifikasi penyakit, sedangkan YOLO lebih sesuai untuk deteksi spasial secara *real-time* terutama pada kondisi lapangan yang dinamis. Arah pengembangan terbaru berfokus pada optimalisasi YOLOv11 agar lebih ringan dan efisien, sehingga dapat dioperasikan pada perangkat portabel maupun sistem *edge* dan mendukung pengembangan pertanian cerdas.

Tabel 1. Tabel Perbandingan Dengan Penelitian Terdahulu

No	Penelitian (Ref)	Hyperparameter Tuning	Overfitting Test	YOLOv11	Daun Teh	Deteksi
1.	Deteksi Penyakit Padi Menggunakan YOLO [8]					✓
2.	Tea Leaf Disease Detection Based on YOLOv7 [3]	✓			✓	✓
3.	YOLO-MECD: Citrus Detection Algorithm Based on YOLOv11 [10]	✓		✓		✓
4.	Implementasi YOLOv8 dan YOLOv11 untuk Pelanggaran Pakaian di Kampus [19]	✓		✓		✓

5.	Pemanfaatan YOLO untuk Deteksi Hama dan Penyakit Daun Cabai [6]							✓
6.	Implementasi YOLOv8 dalam Deteksi Penyakit Daun Durian [7]	✓						✓
7.	YOLOv8-RMDA: <i>Lightweight YOLOv8 Network for Early Detection of Small Target Diseases in Tea</i> [20]	✓					✓	✓
8.	CNNs for Tea Leaf Disease Detection [21]	✓					✓	✓
9.	Klasifikasi Penyakit Padi Menggunakan Algoritma CNN (<i>Convolutional Neural Network</i>) [22]	✓						
10.	Klasifikasi Penyakit Padi Menggunakan <i>Convolutional Neural Network</i> [23]	✓						
11.	Deteksi Penyakit Daun Teh Berdasarkan Citra Menggunakan Deep Learning	✓	✓	✓	✓	✓	✓	✓

Tabel 1 menggambarkan posisi penelitian ini dibandingkan dengan penelitian terdahulu. Penulis menambahkan beberapa langkah untuk memastikan adanya kebaruan dalam penerapan algoritma, termasuk *overfitting test*, *hyperparameter tuning*, penggunaan YOLOv11, variasi dataset yang digunakan, serta perbedaan pada alur kerja proses deteksi.

Pengumpulan Dataset

Penelitian ini menggunakan dataset citra daun teh yang terbagi ke dalam empat kelas, yaitu daun sehat dan daun yang terinfeksi *Tea Leaf Blight*, *Tea Red Leaf Spot*, serta *Tea Red Scab*. Dataset berasal dari *Advanced Tea Crop Disease Study* yang tersedia melalui laman <https://data.mendeley.com/datasets/tt2smzrzrs/4>. Jumlah citra yang digunakan sebanyak 3144 gambar, dengan distribusi 2268 citra untuk kelas Healthy, 502 citra untuk *Tea Leaf Blight*, 546 citra untuk *Tea Red Leaf Spot*, dan 618 citra untuk *Tea Red Scab*.



Gambar 2. Sample Dataset

Gambar 2 menampilkan contoh dataset yang digunakan, terdiri dari empat kelas, yaitu Healthy (Gambar 2a), *Tea Red Scab* (Gambar 2b), *Tea Leaf Blight* (Gambar 2c), dan *Tea Red Leaf Spot* (Gambar 2d).

Perancangan


Tahap perancangan deteksi objek berbasis YOLOv11 diawali dengan pra-pemrosesan citra. Ukuran setiap gambar disesuaikan menjadi 640×640 piksel, sesuai

ukuran awal yang digunakan oleh algoritma YOLO (Yudhi *et al.*, 2025). Setelah itu dilakukan *min-max normalization*, dan proses anotasi dataset dilaksanakan melalui platform *Roboflow*. Dataset yang telah dianotasi kemudian dibagi menjadi tiga bagian, yakni 80 persen untuk *training*, 10 persen untuk *validation*, dan 10 persen untuk *testing*. Rincian pembagian dataset dapat dilihat pada Tabel 2.

Tabel 2. Tabel Pembagian Dataset

Kelas	Train	Validation	Test	Total
<i>Healthy</i>	1814	227	227	2268
<i>Tea Leaf Blight</i>	400	51	51	502
<i>Tea Red Leaf Spot</i>	436	55	55	546
<i>Tea Red Scab</i>	494	62	62	618
Total	3144	395	395	3934

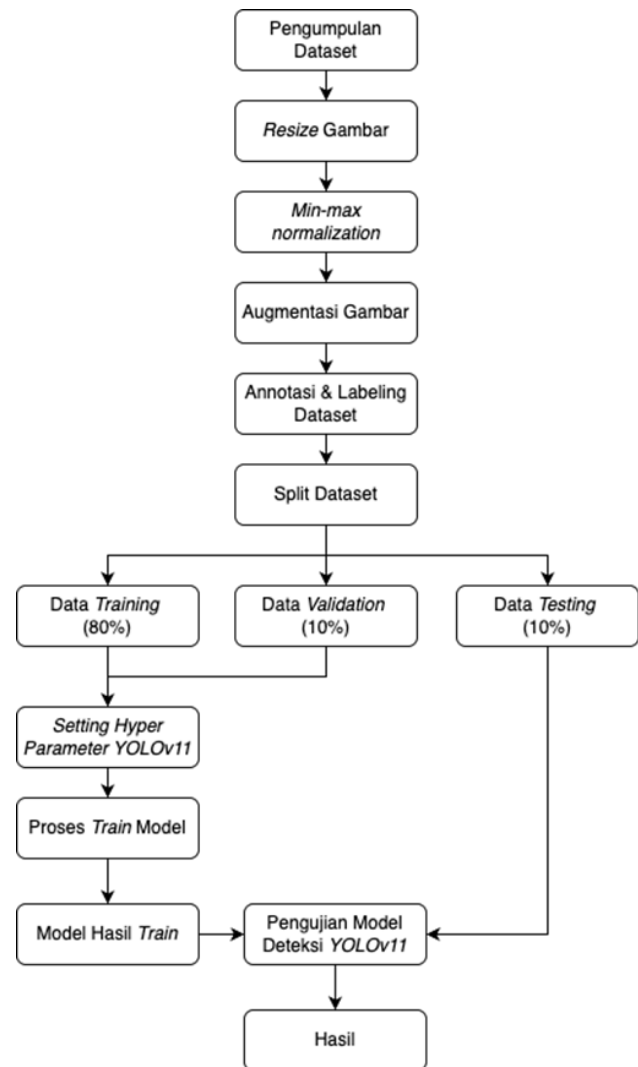
Pada Tabel 2 dapat dilihat ada ketidakseimbangan data, Dimana data *healthy* lebih banyak dari ketiga data lainnya maka dari itu kita perlu melakukan overfitting dan underfitting test menggunakan *learning curve*.



Gambar 3. Kurva Hasil Training 40 Epoch

Berdasarkan grafik pada Gambar 3, pelatihan selama 40 *epoch* menunjukkan bahwa model berada pada kondisi yang stabil. Kurva *train box_loss*, *cls_loss*, dan *dfl_loss* menurun secara konsisten, menandakan bahwa model mampu mempelajari pola objek, kelas, serta posisi *bounding box* dari dataset. Pada kurva *validation*, yaitu *val box_loss*, *val cls_loss*, dan *val dfl_loss*, penurunan nilai *loss* juga terlihat pada setiap *epoch*. Pola tersebut mengindikasikan bahwa model tidak sekadar menghafal data pelatihan, tetapi juga mampu mengenali data yang belum pernah dilihat sebelumnya (Barinov *et al.*, 2023). Evaluasi secara keseluruhan menunjukkan bahwa model tidak mengalami *overfitting* maupun *underfitting*.

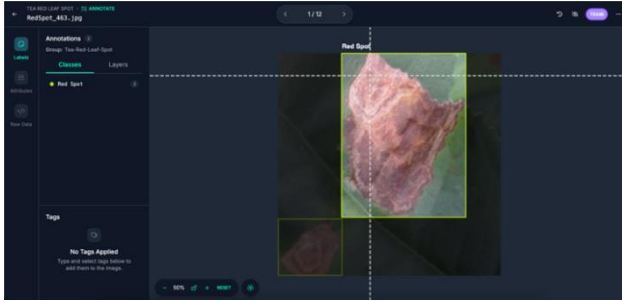
Tahap berikutnya difokuskan pada proses pelatihan lanjutan dengan berbagai pendekatan *hyperparameter tuning* untuk memperoleh performa terbaik. Algoritma YOLOv11 dipilih sebagai dasar model karena efisiensi komputasi dan kemampuannya dalam mendeteksi objek berukuran kecil. Konfigurasi model disusun agar sesuai dengan jumlah kategori penyakit daun teh serta format data yang digunakan. Ilustrasi skema perancangan sistem ditampilkan pada Gambar 4.



Gambar 4. Skema Perancangan Metode YOLOv11

Implementasi

Tahap implementasi dilakukan dengan mengupload dataset daun teh ke aplikasi *Roboflow*. Dataset kemudian diberi bounding box sesuai kelas penyakit secara otomatis dengan fitur *Auto Labelling* yang disediakan oleh *Roboflow*.



Gambar 5. Proses *labelling* dataset dengan *bounding box* Auto Label Roboflow


Dataset yang telah selesai dianotasi kemudian diekspor ke format yang kompatibel dengan YOLOv11. Proses pelatihan mencakup beberapa tahap, yaitu *augmentation* (seperti *flip* horizontal dan vertikal, rotasi, serta penyesuaian *brightness*), normalisasi ukuran citra menjadi 640×640 piksel, serta pembagian dataset ke dalam set *train* (80 persen), *validation* (10 persen), dan *test* (10 persen). Model YOLOv11 dilatih menggunakan *framework* Ultralytics YOLO pada perangkat *laptop* Lenovo Legion dengan prosesor Intel Core i7-10750H @ 2.60 GHz, GPU NVIDIA GeForce GTX 1660 Ti (RAM 6 GB), SSD 447 GB, dan RAM 16 GB. Parameter utama yang digunakan selama pelatihan ditampilkan pada Tabel 3.

Tabel 3. Hyper Parameter YOLO

Parameter	Nilai
<i>Epoch</i>	40
<i>Batch Size</i>	32
<i>Image Size</i>	640
<i>Optimizer</i>	SGD

Pengujian

Tahap pengujian dilakukan untuk mengevaluasi performa model YOLOv11 menggunakan dataset uji yang telah dipisahkan sebelumnya sebanyak 395 gambar (10% dari total dataset). Evaluasi dilakukan dengan dua pendekatan utama, yaitu *Confusion Matrix* dan *mean Average Precision (mAP)*. *Confusion Matrix* digunakan untuk menghitung nilai *precision*, *recall*, dan *F1-score* pada masing-masing kelas. Hasil *Confusion Matrix* ditunjukkan pada Gambar 6, di mana terlihat bahwa kelas *Healthy* memiliki tingkat akurasi tertinggi, sedangkan kelas *Tea Red Leaf Spot* menunjukkan tingkat kesalahan deteksi yang lebih tinggi.



Gambar 6. *Confusion Matrix* berdasarkan data *testing*

Selanjutnya, perhitungan *mAP* dilakukan dengan melihat kurva *Precision-Recall* untuk setiap kelas. Hasil pengujian menunjukkan nilai rata-rata *precision* sebesar 97,2%, *recall* 98,2%, *mAP@0.5* 98,8%, dan *mAP@0.5:0.95* sebesar 95,5%.

Evaluasi Dengan *Confusion Matrix*

Evaluasi ini digunakan untuk mengukur performa klasifikasi dari hasil deteksi model. Nilai yang dihitung meliputi:

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

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

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (3)$$

Keterangan:

TP (*True Positive*): Model berhasil mendeteksi penyakit yang memang ada.

FP (*False Positive*): Model mendeteksi penyakit namun objek tersebut sebenarnya sehat.

FN (*False Negative*): Model tidak mendeteksi penyakit padahal sebenarnya ada.

TN (*True Negative*): Model berhasil mendeteksi objek sehat sebagai bukan penyakit.

Evaluasi *mAP (Mean Average Precision)*

Sebagai metrik utama dalam object detection, *mAP* digunakan untuk menilai sejauh mana model mampu mendeteksi dan mengidentifikasi objek penyakit daun teh dengan tepat dan akurat.

mAP@0.5

Mengukur rata-rata presisi dari seluruh kelas penyakit daun teh saat nilai *IoU* (*Intersection over Union*) minimal 0.5.

mAP@0.5:0.95

Merupakan nilai rata-rata presisi dari 10 tingkat *IoU* yang berbeda (mulai dari 0.5 hingga 0.95 dengan interval 0.05), sehingga memberikan gambaran performa model dalam berbagai kondisi overlap antara prediksi dan ground truth. Perhitungan *mAP* dilakukan dengan cara menghitung *AP* (*Average Precision*) untuk masing-masing kelas, lalu dirata-ratakan menjadi *mAP* dengan *n* adalah jumlah kelas penyakit daun teh

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

3. Hasil dan Pembahasan


Hasil

Dataset terdiri dari 3934 gambar yang kemudian dibagi per kelas penyakit daun teh 80% untuk latih, 10% validasi, dan 10% testing. Pelatihan model menggunakan 3144 gambar yang terdiri dari 1814 gambar kelas *Healthy*, 400 gambar kelas *Leaf Blight*, 436 gambar kelas *Red Leaf Spot*, 494 gambar kelas *Red Scab*. Hasil evaluasi pada data uji dengan 394 citra ditampilkan pada Tabel 4.

Tabel 4. Tabel Pembagian Dataset


Kelas	<i>Precision</i>	<i>Recall</i>	<i>mAP@0.5</i>	<i>mAP@0.5:0.95</i>
<i>Healthy</i>	0.997	1.000	0.995	0.993
<i>Tea Leaf Blight</i>	0.931	1.000	0.994	0.965
<i>Tea Red Leaf Spot</i>	0.978	1.000	0.993	0.937
<i>Tea Red Scab</i>	0.982	0.929	0.971	0.923
Rata - rata	0.972	0.982	0.988	0.955

Berdasarkan data pada Tabel 4, model mampu melakukan deteksi penyakit daun teh dengan akurasi tinggi. Nilai rata-rata *precision* mencapai 97,2%, *recall* 98,2%, *mAP@0.5* 98,8%, dan *mAP@0.5:0.95* 95,5%. Kelas *Healthy* dan *Tea Red Spot* menunjukkan akurasi yang sangat tinggi, sedangkan pada kelas *Tea Red Scab* masih terdapat sedikit kesalahan klasifikasi dengan *recall* sebesar 92,9%. Serta dengan waktu proses sebesar 3,9ms yang terdiri dari 1,1ms untuk *preprocess*, 1,8ms untuk *inference*, dan 1ms untuk *postprocess* per gambarnya. Pada Gambar 7 menunjukkan kurva hubungan antara tingkat *confidence* prediksi dengan nilai *precision*. Prediksi model terhadap 4 kelas (*Healthy*, *Blight*, *Tea Red Spot*, dan *Tea Red Scab*) memiliki *precision* yang tinggi, mendekati 1.0 pada *confidence* di atas 0.5. Hasil menunjukkan sebagian besar prediksi model benar, dengan tingkat kesalahan (*false positive*) yang rendah.



Gambar 7. Kurva Precision

Pada Gambar 8 kurva *recall* menunjukkan kemampuan model dalam mengenali semua objek yang benar (*recall*). Hampir semua kelas memiliki *recall* di atas 0,9 pada *confidence* 0 hingga 0.6, meskipun terjadi penurunan pada *confidence* mendekati 1.0, khususnya pada kelas *Tea Red Leaf Spot*. Hal ini menunjukkan bahwa model cukup sensitif dalam mendeteksi objek, tetapi sebagian kecil penyakit sulit dikenali pada ambang batas *confidence* yang sangat tinggi.



Gambar 8. Kurva Recall

Pada Gambar 9 menampilkan visualisasi *bouding box* hasil deteksi pada citra uji. Setiap objek daun berhasil diprediksi dengan label yang sesuai, lengkap dengan skor confidence (misalnya Healthy 1.0, Blight 0.9, Tea Red Spot 1.0). Bounding box berwarna menandakan area penyakit yang terdeteksi, dan hasil ini membuktikan bahwa model mampu mendeteksi lokasi serta jenis penyakit pada daun teh secara akurat.



Gambar 9. Hasil implementasi model

Berdasarkan penelitian terdahulu, deteksi penyakit daun teh menggunakan *YOLOv7* mampu mencapai $mAP@0.5$ sebesar 98,2 persen (Soeb *et al.*, 2023). Pada penelitian ini, *YOLOv11* memperoleh $mAP@0.5$ sebesar 98,8 persen, yang menunjukkan bahwa versi tersebut memberikan hasil lebih baik untuk tugas deteksi penyakit daun teh. Meskipun demikian, distribusi kelas dalam dataset tidak

seimbang, dengan jumlah citra kelas Healthy jauh lebih banyak dibandingkan kelas penyakit. Ketimpangan tersebut dapat memicu kecenderungan model untuk memberikan prediksi ke kelas mayoritas. Evaluasi melalui *Confusion Matrix* pada Gambar 6 menunjukkan bahwa beberapa kelas penyakit masih mengalami kesalahan prediksi. Hal tersebut mengindikasikan bahwa ketidakseimbangan data turut memengaruhi kemampuan model dalam mengenali kelas minoritas. Walaupun terdapat bias terkait distribusi kelas, nilai mAP secara keseluruhan tetap tinggi. Model masih dapat dinilai andal dan tidak menunjukkan gejala *overfitting* maupun *underfitting*.

Pembahasan

Model yang dibangun pada penelitian ini mampu mengenali empat jenis kondisi daun teh dengan tingkat ketelitian yang tinggi. Rata-rata ketepatan mencapai 97,2 persen dan kemampuan mengenali gejala mencapai 98,2 persen. Hasil tersebut menunjukkan bahwa model bekerja stabil dan jarang melewati tanda penyakit. Temuan ini sejalan dengan penelitian Soeb dan rekan (2023) yang memanfaatkan *YOLOv7* dan memperoleh ketepatan yang juga tinggi. Pada penelitian saat ini, capaian ketelitian pada batas nilai kesesuaian 0,5 sedikit lebih tinggi dibanding penelitian tersebut, sehingga teknologi yang digunakan memiliki potensi peningkatan kinerja. Pencapaian model juga sejalan dengan penelitian Putra dan rekan (2024) pada daun durian dan Yassen dan rekan (2023) pada daun cabai. Keduanya menunjukkan bahwa pendekatan pendeteksian berbasis satu kali lihat bekerja baik untuk berbagai bentuk dan kondisi daun. Hal yang sama terlihat pada penelitian ini, di mana model tetap stabil meskipun citra memiliki variasi warna, ukuran bercak, dan tingkat kerusakan yang berbeda. Penelitian ini menghadapi tantangan berupa ketidakseimbangan jumlah gambar antara kelas sehat dan kelas penyakit. Kondisi tersebut membuat sebagian prediksi condong ke kelas sehat. Temuan ini terlihat dari beberapa kesalahan pada kelas Tea Red Scab. Pola serupa juga ditemukan pada penelitian Ye dan rekan (2024), di mana penyakit berukuran kecil atau bercak dengan warna mendekati latar daun lebih sulit dikenali ketika jumlah datanya tidak seimbang. Walaupun begitu, nilai ketepatan rata-rata pada berbagai batas kesesuaian tetap tinggi, sehingga model masih dapat diandalkan. Hasil visualisasi kotak

penanda menunjukkan bahwa model mampu menunjukkan lokasi dan jenis penyakit dengan tepat. Kurva kerugian pada pelatihan dan pengujian juga menurun secara teratur. Pola tersebut sejalan dengan penjelasan Barinov dan rekan (2023) yang menyatakan bahwa penurunan kerugian yang stabil menjadi penanda bahwa model merespons pelatihan dengan baik dan tidak menghafal data pelatihan. Jika dibandingkan dengan pendekatan berbasis jaringan saraf konvolusi yang digunakan Rahat dan rekan (2025), metode pada penelitian ini memiliki kelebihan karena dapat menunjukkan posisi penyakit secara langsung, bukan hanya menentukan jenis penyakit. Informasi lokasi ini penting bagi petani karena mempermudah pengamatan bagian daun yang bermasalah. Secara umum, hasil penelitian memperlihatkan bahwa model yang dibangun memiliki kemampuan memadai untuk digunakan pada kebun teh. Kinerjanya konsisten dengan arah penelitian sebelumnya yang menekankan peningkatan ketelitian, kemampuan mengenali gejala kecil, serta kecepatan pemrosesan. Hal ini membuka peluang penerapan sistem pendeteksian dini yang lebih terjangkau dan cepat dalam praktik budidaya teh.

4. Kesimpulan dan Saran

Penelitian mengenai deteksi penyakit daun teh berbasis citra berhasil menerapkan YOLOv11 untuk mengenali empat jenis kondisi daun, yaitu sehat, Blight, Red Leaf Spot, dan Red Scab. Model yang dibangun menunjukkan kinerja yang kuat dengan rata-rata ketepatan 97,2 persen, kemampuan mengenali gejala 98,2 persen, serta nilai ketepatan rata-rata pada batas kesesuaian 0,5 sebesar 98,8 persen dan pada rentang batas kesesuaian 0,5 hingga 0,95 sebesar 95,5 persen. Hasil visualisasi menunjukkan bahwa lokasi penyakit pada daun teridentifikasi dengan tepat dan waktu pemrosesan per gambar berlangsung cepat. Temuan ini menegaskan bahwa YOLOv11 layak diterapkan sebagai sistem pendeteksian otomatis untuk mendukung petani dan pengelola kebun teh dalam mengenali gejala penyakit sejak awal sehingga tindakan pengendalian dapat dilakukan lebih cepat dan lebih tepat.

5. Ucapan Terima Kasih

Terima kasih kepada kedua orang tua penulis dan bapak Dedy Hermanto selaku pembimbing skripsi selama penelitian.

6. Daftar Pustaka

- Barinov, R., Gai, V., Kuznetsov, G., & Golubenko, V. (2023). Automatic evaluation of neural network training results. *Computers*, 12(9), 177. <https://doi.org/10.3390/computers12090177>.
- Bitra, M., & Dewi, C. (n.d.). Penggunaan YOLOv8 untuk deteksi penyakit daun kopi.
- Gangadharan, S., Immidichetty, S., Gandhamueni, S., Mupparaju, Y., Gottipati, S., & Simon, U. J. J. (2025). Precision weed detection using YOLOv11 for enhanced agriculture management. *International Journal of Agriculture Extension and Social Development*, 8(5), 659–666. <https://doi.org/10.33545/26180723.2025.v8.i5i.1965>.
- Gao, L., Cao, H., Zou, H., & Wu, H. (2025). DMN-YOLO: A robust YOLOv11 model for detecting apple leaf diseases in complex field conditions. *Agriculture*, 15(11). <https://doi.org/10.3390/agriculture15111138>.
- Hawari, F. H., Fadillah, F., Alviandi, M. R., & Arifin, T. (2025). Klasifikasi penyakit padi menggunakan algoritma CNN (Convolutional Neural Network). *Jurnal Teknologi Informasi*, 185.
- Jegham, N., Koh, C. Y., Abdelatti, M., & Hendawi, A. (2024). YOLO evolution: A comprehensive benchmark and architectural review of YOLOv12, YOLO11, and their previous versions. <http://arxiv.org/abs/2411.00201>.
- Khanam, R., & Hussain, M. (2024). YOLOv11: An overview of the key architectural enhancements. <http://arxiv.org/abs/2410.17725>.

- Khoiruddin, M., Junaidi, A., & Saputra, W. A. (2022). Klasifikasi penyakit daun padi menggunakan Convolutional Neural Network. *Journal of Dinda*, 2(1), 37–45.
- Krisdianto, K., Sonalitha, E., & Gumilang, Y. S. A. (2024). Deteksi penyakit padi menggunakan YOLO. *Uranus: Jurnal Ilmiah Teknik Elektro, Sains dan Informatika*, 2(3), 125–134. <https://doi.org/10.61132/uranus.v2i3.259>.
- Liao, Y., Li, L., Xiao, H., Xu, F., Shan, B., & Yin, H. (2025). YOLO-MECD: Citrus detection algorithm based on YOLOv11. *Agronomy*, 15(3). <https://doi.org/10.3390/agronomy15030687>.
- Lv, Z., et al. (2025). Efficient deployment of peanut leaf disease detection models on edge AI devices. *Agriculture*, 15(3). <https://doi.org/10.3390/agriculture15030332>
- Putra, R. R., Maimunah, M., & Sasongko, D. (2024). Implementasi algoritma YOLO V8 dalam deteksi penyakit daun durian. *Building of Informatics, Technology and Science (BITS)*, 6(3). <https://doi.org/10.47065/bits.v6i3.6136>.
- Rahat, I. S., Ghosh, H., Dara, S., & Kant, S. (2025). Towards precision agriculture tea leaf disease detection using CNNs and image processing. *Scientific Reports*, 15, 17571. <https://doi.org/10.1038/s41598-025-02378-0>.
- Rimon, S., Bormon, M. H., Ahmad, S. R., Sohag, S. R., & Akhi, A. B. (2025). High-resolution dataset for tea garden disease management: Precision agriculture insights. *Data in Brief*, 59. <https://doi.org/10.1016/j.dib.2025.111379>.
- Soeb, M. J. A., et al. (2023). Tea leaf disease detection and identification based on YOLOv7 (YOLO-T). *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-33270-4>.
- Tang, X., et al. (2025). YOLOv11-AIU: A lightweight detection model for the grading detection of early blight disease in tomatoes. *Plant Methods*, 21(1). <https://doi.org/10.1186/s13007-025-01435-z>.
- Teng, H., Wang, Y., Li, W., Chen, T., & Liu, Q. (2025). Advancing rice disease detection in farmland with an enhanced YOLOv11 algorithm. *Sensors*, 25(10). <https://doi.org/10.3390/s25103056>.
- Wang, K., Liu, J., & Cai, X. (n.d.). C2PSA-enhanced YOLOv11 architecture: A novel approach for small target detection in cotton disease diagnosis.
- Yasen, N. M., Rifka, S., Vitria, R., & Yulindon, Y. (2023). Pemanfaatan YOLO untuk deteksi hama dan penyakit pada daun cabai menggunakan metode deep learning. *Elektron: Jurnal Ilmiah*, 63–71. <https://doi.org/10.30630/eji.0.0.397>.
- Ye, R., Shao, G., He, Y., Gao, Q., & Li, T. (2024). YOLOv8-RMDA: Lightweight YOLOv8 network for early detection of small target diseases in tea. *Sensors*, 24(9), 2896. <https://doi.org/10.3390/s24092896>.
- Yudhi, M. F., Erzed, N., Yulhendri, & Asri, J. S. (2025). Implementasi perbandingan YOLO v8 dan YOLO v11 dalam penerapan tata tertib berpakaian di lingkungan kampus: Studi kasus Universitas Esa Unggul Kampus Bekasi. *Kohesi: Jurnal Multidisiplin Saintek*, 7(3). <https://doi.org/10.8734/Kohesi.v1i2.365>.