



Klasifikasi Penyakit Daun Mangga Menggunakan YOLOv11 Berbasis Deep Learning dan Computer Vision

Andrian Wijaya*, Nur Rachmat

Fakultas Ilmu Komputer dan Rekayasa, Program Studi Informatika, Universitas Multi Data Palembang, Kota Palembang, Indonesia

Email: ^{1,*}wandrian404@mhs.mdp.ac.id, ²nur.rachmat@mdp.ac.id

Email Penulis Korespondensi: wandrian404@mhs.mdp.ac.id¹

Abstrak—Sektor pertanian mangga di Indonesia masih menghadapi permasalahan serius akibat penyakit pada daun yang menurunkan produktivitas tanaman. Identifikasi penyakit secara konvensional dinilai kurang efisien karena bergantung pada pengamatan *visual* yang *subjektif*. Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit daun mangga menggunakan *algorithm deep learning YOLOv11*. Model ini dipilih karena memiliki klasifikasi objek secara *real-time* dengan keseimbangan optimal antara akurasi dan kecepatan. Penelitian akan menggunakan *dataset Mango Leaf Disease* dari Kaggle yang terdiri atas delapan kelas (tujuh penyakit dan satu daun sehat). Tahapan penelitian mencakup *preprocessing*, *image augmentation*, pembagian data dengan *K-Fold Cross Validation*, serta *hyperparameter tuning* pada *optimizer*, *learning rate*, *epoch*, dan *batch size*. Evaluasi performa akan dilakukan menggunakan *Confusion Matrix*. Diharapkan, penelitian ini dapat menghasilkan model klasifikasi yang akurat dan efisien, serta mendukung deteksi dini penyakit daun mangga secara objektif dan cepat. Dataset yang digunakan berasal dari Kaggle yang terdiri dari 4.000 citra yang terbagi ke dalam delapan kelas (tujuh jenis penyakit dan satu kelas daun sehat). Metodologi penelitian mencakup tahap *preprocessing* (*resizing 640x640* dan *normalisasi*), *augmentasi gambar*, serta pembagian data menggunakan *10-Fold Cross Validation*. Pengujian dilakukan dengan melakukan *hyperparameter tuning* pada *optimizer Adam*, *learning rate 0,001*, *batch size 16*, dan variasi *epoch*. Hasil penelitian menunjukkan bahwa model *YOLOv11s* mampu mencapai performa yang sangat optimal dan stabil. Berdasarkan evaluasi menggunakan *Confusion Matrix*, model berhasil mencapai tingkat akurasi, *presisi*, *recall*, dan *F1-score* sebesar 100% pada dataset penelitian yang digunakan. Rata-rata nilai *training loss* yang dihasilkan adalah sebesar 0,0979 dan *validation loss* sebesar 0,0027. Dengan efisiensi komputasi yang tinggi, model ini berpotensi besar untuk diimplementasikan pada perangkat *mobile* guna mendukung deteksi dini penyakit tanaman mangga secara objektif dan cepat di lapangan. Sebagai kontribusi ilmiah, penelitian ini menyajikan evaluasi komprehensif penerapan *YOLOv11s* untuk klasifikasi penyakit daun mangga dengan skema *10-Fold Cross Validation*, analisis kestabilan model berdasarkan *validation loss*, serta kajian potensi implementasi pada sistem deteksi *real-time* berbasis perangkat *mobile*.

Kata Kunci: YOLOv11; Klasifikasi Penyakit Daun Mangga; *Deep Learning*; *Computer Vision*

Abstract—Indonesia's mango agriculture sector continues to face significant challenges due to leaf diseases that reduce crop productivity. Conventional disease identification methods remain inefficient because they rely on subjective visual observation. This study aims to develop a mango leaf disease classification model using the YOLOv11 deep learning algorithm. YOLOv11 is chosen for its capability in real-time object classification with an optimal balance between accuracy and processing speed. The research will utilize the Mango Leaf Disease dataset from Kaggle, consisting of eight classes (seven disease types and one healthy class). The planned methodology includes preprocessing, image augmentation, data splitting using K-Fold Cross Validation, and hyperparameter tuning on optimizer, learning rate, epoch, and batch size. Model performance will be evaluated using the Confusion Matrix. This research is expected to produce an accurate and efficient classification model that enables objective and rapid early detection of mango leaf diseases. The research utilizes a dataset from Kaggle consisting of 4,000 images across eight classes—comprising seven disease types and one healthy leaf class. The methodology involves preprocessing (resizing to 640x640 pixels and normalization), image augmentation, and data splitting using 10-Fold Cross Validation. Performance was optimized through hyperparameter tuning of the Adam optimizer, a learning rate of 0.001, a batch size of 16, and various epoch settings. The experimental results demonstrate that the YOLOv11s model achieves exceptional and stable performance. Evaluation using a Confusion Matrix shows that the model reached a 100% accuracy, precision, recall, and F1-score on the dataset used in this study. The model recorded an average training loss of 0.0979 and a validation loss of 0.0027. These findings confirm that YOLOv11s is not only highly accurate but also computationally efficient, making it a viable candidate for real-time detection systems on mobile or edge computing devices to support early disease detection in mango orchards. As the main contribution, this study provides a comprehensive evaluation of YOLOv11s for mango leaf disease classification using a 10-Fold Cross Validation scheme, stability analysis based on validation loss, and an assessment of its potential for real-time deployment on mobile and edge computing devices.

Keywords: YOLOv11; Mango Leaf Disease Classification; Deep Learning; Computer Vision

1. PENDAHULUAN

Mangga (*Mangifera indica L.*) adalah buah tropis penting yang banyak dibudidayakan, tidak terkecuali di Indonesia. Buah ini punya nilai jual tinggi dikarenakan kaya *vitamin* dan antioksidan yang bikin tubuh lebih sehat (Harmiansyah et al., 2024). Sebagai negara penghasil mangga besar di dunia, bisnis mangga di sini sangat membantu petani dapat penghasilan lebih sekaligus jadi sumber *devisa* nasional yang cukup. Data statistik menunjukkan bahwa produksi mangga nasional memiliki *volume* yang cukup besar, namun kerap mengalami fluktuasi dari tahun ke tahun. Badan Pusat Statistik (BPS) melaporkan adanya penurunan produktivitas pada tahun 2021, yang mencerminkan tantangan dalam stabilitas produksi (Harmiansyah et al., 2024). Ketidakstabilan ini berdampak tidak hanya pada pasokan domestik, tetapi juga pada potensi ekspor. Salah satu penyebab utama kerugian hasil panen, baik dari segi kuantitas maupun kualitas, adalah serangan organisme pengganggu tanaman, khususnya hama dan penyakit. Di antara berbagai penyakit yang menyerang tanaman mangga, infeksi yang disebabkan oleh jamur patogen merupakan ancaman paling serius. Beberapa penyakit daun mangga yang umum dijumpai di lapangan meliputi *Antraknosa*, *Powdery Mildew*, *Sooty*



Mold, Bacterial Canker, serta bercak daun akibat infeksi patogen lainnya. Salah satu penyakit utama adalah antraknosa, yang disebabkan oleh *Colletotrichum gloeosporioides*, dan dikenal sebagai penyakit pascapanen yang dapat menyebabkan kerugian ekonomi signifikan (Arti et al., 2022). Penyakit ini menyerang berbagai bagian tanaman, termasuk buah, daun, dan ranting, namun gejala paling parah biasanya muncul pada buah matang berupa bercak hitam cekung yang menurunkan kualitas dan nilai jualnya.

Identifikasi penyakit mangga di lapangan hingga kini masih banyak dilakukan secara konvensional melalui observasi *visual* oleh petani atau penyuluh pertanian. Pendekatan dua tahap dalam deteksi penyakit daun mampu meningkatkan akurasi lokalisasi dan klasifikasi secara simultan (Yao et al., 2022). Dalam beberapa tahun terakhir, kemajuan teknologi *deep learning* dan visi komputer telah dimanfaatkan untuk mendeteksi penyakit tanaman, termasuk pada mangga. Model berbasis *deep learning* telah diterapkan dalam berbagai studi untuk meningkatkan reliabilitas sistem deteksi penyakit tanaman (Jung et al., 2023). Penelitian seperti “*Mango Leaf Disease Classification using Deep Learning*” menunjukkan bahwa model *Convolutional Neural Network* (CNN) mampu mengklasifikasikan berbagai jenis penyakit daun mangga dengan tingkat akurasi yang tinggi (Ahmed et al., 2022). Model CNN ringan seperti MobileNet telah digunakan untuk meningkatkan efisiensi komputasi dalam sistem deteksi penyakit daun (Ashwinkumar et al., 2022). Lebih lanjut, pendekatan berbasis deteksi objek seperti algoritma YOLO (*You Only Look Once*) mulai banyak digunakan karena kemampuannya tidak hanya dalam klasifikasi, tetapi juga dalam menentukan lokasi area penyakit pada citra.

Algoritma deteksi objek berbasis YOLO dilaporkan efektif untuk aplikasi pertanian yang membutuhkan pemrosesan secara *real-time* (Caldeira et al., 2021). Penelitian terbaru melaporkan bahwa penerapan algoritma YOLOv4 mampu meningkatkan akurasi deteksi penyakit daun tanaman secara signifikan pada berbagai kondisi citra lapangan (Aldakheel et al., 2024). Studi terbaru bahkan melaporkan peningkatan kinerja model YOLOv8 dalam mendeteksi penyakit daun mangga dibandingkan metode terdahulu. Pendekatan berbasis YOLOv8 yang telah ditingkatkan juga dilaporkan efektif dalam mengenali bercak penyakit pada daun jagung, menunjukkan potensi generalisasi algoritma YOLO pada berbagai komoditas (Yang et al., 2024). Meskipun demikian, masih terdapat kesenjangan penelitian yang perlu diatasi.

Beberapa studi melaporkan bahwa metode berbasis CNN menghadapi sejumlah keterbatasan, seperti keterbatasan ukuran *dataset*, variasi pencahayaan dan sudut pengambilan gambar, serta kemampuan generalisasi yang rendah terhadap kondisi lapangan nyata (Preeya V et al., 2024). Pengembangan varian YOLO untuk pertanian presisi, seperti YOLO-Leaf, telah menunjukkan kinerja yang baik dalam mendeteksi penyakit daun apel dengan tingkat presisi yang tinggi (Li et al., 2024). Studi pada lingkungan rumah kaca menunjukkan bahwa algoritma YOLOv8 yang dimodifikasi mampu meningkatkan akurasi deteksi penyakit sayuran secara signifikan, terutama pada kondisi latar belakang yang kompleks (Wang & Liu, 2024). Selain itu, penelitian yang secara spesifik menguji versi terbaru YOLO, seperti YOLOv11, untuk klasifikasi penyakit daun mangga masih sangat terbatas. Penerapan teknik *deep learning* pada deteksi penyakit daun telah menunjukkan kinerja yang konsisten pada berbagai jenis tanaman hortikultura (Chowdhury et al., 2021). Hal ini membuka peluang penelitian baru untuk mengevaluasi keunggulan YOLOv11 dalam hal kecepatan dan akurasi pada konteks nyata di lapangan. Pendekatan *Convolutional Neural Network* (CNN) banyak digunakan karena kemampuannya dalam mengekstraksi fitur visual secara otomatis dari citra daun (Abade et al., 2021). Penggunaan algoritma YOLO dalam deteksi penyakit tanaman memiliki sejumlah keunggulan, antara lain kemampuan deteksi satu tahap (*single-stage detection*) yang memungkinkan pemrosesan citra secara lebih cepat dibandingkan model dua tahap, kemampuan simultan dalam klasifikasi dan lokalisasi area penyakit melalui *bounding box*, serta potensi penerapan secara waktu nyata pada perangkat bergerak. Keunggulan ini menjadikan YOLO sangat relevan untuk mendukung pengambilan keputusan cepat di tingkat petani, dengan efisiensi komputasi yang tinggi bahkan pada perangkat dengan sumber daya terbatas. Beberapa penelitian juga menunjukkan bahwa YOLO unggul dalam kondisi yang menuntut kecepatan dan akurasi tinggi, baik pada tanaman mangga maupun komoditas lainnya (Arcila-Diaz et al., 2024). Metode identifikasi penyakit tanaman berbasis *deep learning* telah dilaporkan mampu meningkatkan akurasi dibandingkan pendekatan konvensional berbasis fitur manual (Liu & Wang, 2021).

Oleh karena itu, penelitian ini memiliki urgensi tinggi, baik dari sisi akademik maupun praktis. Dari sisi akademik, penelitian ini bertujuan mengisi kesenjangan dengan mengeksplorasi penerapan YOLOv11 dalam klasifikasi penyakit daun mangga, yang hingga kini belum banyak dikaji. Dari sisi praktis, hasil penelitian diharapkan dapat memberikan kontribusi nyata bagi petani mangga melalui deteksi dini penyakit daun, sehingga dapat meningkatkan produktivitas, mengurangi kehilangan hasil, dan memperkuat daya saing komoditas mangga nasional. Studi terbaru melaporkan bahwa integrasi metode *deep learning* dapat meningkatkan kemampuan generalisasi model pada berbagai kondisi pencahayaan dan latar belakang (Sudhesh et al., 2023). Dengan demikian, penelitian ini diharapkan berperan penting dalam pengembangan sistem deteksi penyakit berbasis visi komputer yang andal dan aplikatif di lapangan. Seiring perkembangannya, keluarga model YOLO (dari v1 hingga versi terbaru seperti v8 dan seterusnya) terus mengalami penyempurnaan signifikan untuk menyeimbangkan kecepatan dan akurasi (*Mean Average Precision* atau *mAP*). Penerapan sistem berbasis CNN pada perangkat keras khusus dilaporkan mampu meningkatkan efisiensi pemrosesan untuk aplikasi pertanian presisi (Perumal et al., 2024). Versi-versi yang lebih baru sering kali menggabungkan arsitektur backbone yang lebih *efisien* dan teknik *feature fusion* yang canggih. Peningkatan ini sangat relevan untuk deteksi penyakit tanaman, karena gejala awal sering kali muncul sebagai lesi atau bintik-bintik kecil yang sulit dideteksi oleh model yang lebih tua. Dengan memanfaatkan arsitektur yang lebih modern, penelitian ini bertujuan

untuk mencapai akurasi deteksi yang lebih tinggi, terutama dalam mengidentifikasi infeksi pada tahap paling awal, yang merupakan kunci untuk pencegahan penyebaran penyakit yang efektif (Han et al., 2023).

Meskipun berbagai penelitian sebelumnya telah menerapkan pendekatan *deep learning* dan algoritma YOLO untuk deteksi penyakit tanaman, sebagian besar studi masih berfokus pada versi YOLO generasi awal hingga menengah, seperti YOLOv5 dan YOLOv8, serta umumnya menggunakan skema pembagian data konvensional tanpa validasi silang yang *komprensif*. Selain itu, kajian yang secara khusus menguji kemampuan YOLO versi terbaru dalam mengklasifikasikan beragam jenis penyakit daun mangga secara simultan masih sangat terbatas. Hal ini menunjukkan adanya kesenjangan penelitian (*research gap*) dalam evaluasi kinerja YOLOv11 pada konteks penyakit daun mangga dengan jumlah kelas yang *kompleks* dan evaluasi yang lebih *robust*. Berdasarkan kesenjangan tersebut, penelitian ini berkontribusi dengan mengkaji penerapan algoritma YOLOv11 dalam klasifikasi tujuh jenis penyakit daun mangga dan satu kelas daun sehat, menerapkan skema evaluasi *10-Fold Cross Validation* untuk meningkatkan objektivitas dan reliabilitas hasil, serta menyajikan analisis performa model yang berpotensi dikembangkan ke sistem deteksi penyakit tanaman berbasis *real-time*. Kontribusi ini diharapkan dapat memperkaya kajian *computer vision* di bidang pertanian serta menjadi landasan bagi pengembangan sistem deteksi penyakit tanaman yang lebih aplikatif di lapangan.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

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



Gambar 1. Tahapan Metodologi Penelitian

Pada Gambar 1, penelitian ini dirancang menggunakan pendekatan eksperimental dengan tujuan mengembangkan dan mengevaluasi model klasifikasi penyakit daun mangga berbasis *deep learning* menggunakan algoritma YOLOv11. Tahapan penelitian disusun secara sistematis untuk memastikan bahwa setiap proses berjalan terstruktur dan dapat direproduksi. Secara umum, tahapan penelitian meliputi studi literatur, pengumpulan dataset, pra-pemrosesan data, pembagian data menggunakan *K-Fold Cross Validation*, pelatihan model, serta evaluasi performa *model*. Tahap awal penelitian diawali dengan studi literatur terhadap jurnal dan publikasi ilmiah yang membahas klasifikasi penyakit tanaman, khususnya daun mangga, serta penerapan algoritma *Convolutional Neural Network* (CNN) dan YOLO dalam bidang pertanian. Studi literatur ini bertujuan untuk memperoleh pemahaman teoritis, mengidentifikasi pendekatan yang telah dilakukan sebelumnya, serta menentukan celah penelitian yang relevan.

2.2 Pengumpulan Dataset

Pada tahap ini, dilakukan proses pengumpulan *dataset* penyakit pada daun mangga yang diambil pada website kaggle yang memiliki 8 *class* yaitu 7 *class* penyakit pada daun mangga dan 1 *class* daun mangga yang sehat <https://www.kaggle.com/datasets/aryashah2k/mango-leaf-disease-dataset> (Ali et al., 2022).

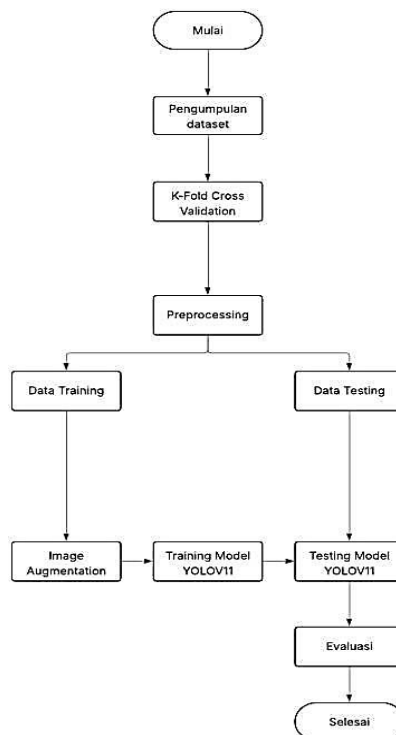
2.3 Perancangan

Tahap perancangan bertujuan untuk menyusun alur pemrosesan data dan konfigurasi model yang akan digunakan dalam penelitian. Tahapan pra-pemrosesan citra merupakan langkah penting untuk meningkatkan kualitas data latih dan stabilitas proses pelatihan model (Abade et al., 2021). Proses diawali dengan pembagian dataset menggunakan metode *10-Fold Cross Validation*, di mana pada setiap *fold* data dibagi menjadi 90% data latih dan 10% data uji. Skema pembagian data menggunakan validasi silang direkomendasikan untuk meningkatkan objektivitas evaluasi performa model (Liu & Wang, 2021). Pembagian data dilakukan terlebih dahulu sebelum proses augmentasi untuk memastikan tidak terjadi *data leakage* antara data *training* dan data *testing*. Selanjutnya dilakukan tahap *pre-processing* yang

meliputi *resizing* dan *normalisasi* citra. Proses *resizing* dilakukan dari ukuran asli 240×320 piksel menjadi 640×640 piksel menggunakan teknik *letterbox resizing*, yaitu mempertahankan rasio aspek asli citra dan menambahkan *padding* pada sisi tertentu. Teknik ini digunakan untuk mencegah *distorsi* bentuk daun yang dapat memengaruhi ekstraksi fitur *visual* oleh *model*. *Normalisasi* dilakukan untuk menyamakan skala nilai piksel sehingga mempercepat proses konvergensi saat pelatihan model. Setelah proses *pre-processing*, dilakukan *image augmentation* hanya pada data *training* di setiap *fold*. Teknik augmentasi citra digunakan untuk meningkatkan variasi data latih dan mengurangi risiko *overfitting* selama proses pelatihan (Chowdhury et al., 2021). Teknik augmentasi yang digunakan meliputi *flipping*, *rotation*, *scaling*, *translation*, dan *cropping*. Penerapan augmentasi ini bertujuan untuk meningkatkan variasi data latih dan mengurangi risiko *overfitting*, tanpa memengaruhi data testing yang digunakan sebagai data evaluasi. Evaluasi performa model menggunakan metrik klasifikasi standar digunakan secara luas dalam penelitian deteksi penyakit tanaman berbasis *deep learning* (Jung et al., 2023). Data yang telah diproses selanjutnya dimasukkan ke dalam arsitektur YOLOv11s. Untuk memperoleh performa optimal, dilakukan *hyperparameter tuning* terhadap beberapa parameter utama, yaitu *optimizer*, *jumlah epoch*, *batch size*, dan *learning rate*. *Optimizer* yang digunakan adalah *Adam* karena mampu memberikan konvergensi yang cepat dan stabil. Pemilihan arsitektur CNN yang efisien dapat membantu menurunkan beban komputasi tanpa mengorbankan performa klasifikasi (Ashwinkumar et al., 2022). Variasi *epoch* yang digunakan adalah 35, 50, dan 100 *epoch* untuk menghindari *overfitting*. *Batch size* ditetapkan sebesar 16 sebagai kompromi antara efisiensi pemrosesan dan penggunaan *memori*, sedangkan *learning rate* ditetapkan sebesar 0,001 sebagai nilai awal yang umum digunakan pada pelatihan *model deep learning*. Setelah model dilatih, pengujian model akan dilakukan menggunakan data *testing*. Hasil uji coba didapat dengan metode *Confusion Matrix* yang terdiri dari *accuracy*, *precision*, *recall*, dan *f1-score*. Skema perancangan dapat dilihat pada Gambar 2.

Tabel 1. Hyperparameter Tuning

No.	Hyperparameter	Nilai Uji	Jenis Nilai	Alasan pemilihan
1	Optimizer	Adam	Tetap	Efisiensi dan konvergensi yang cepat
2	Epoch	35, 50, dan 100	Variasi	Model tidak mengalami <i>overfitting</i>
3	Batch Size	16	Tetap	Penyeimbangan efisiensi pemrosesan dan vram yang digunakan selama pelatihan
4	Learning rate	0.001	Tetap	<i>Learning rate</i> awal yang standar untuk algoritma <i>Deep Learning</i>



Gambar 2. Skema Perancangan YOLOv11

Pada Gambar 2, dapat dilihat tahap perancangan yang bertujuan untuk menyusun alur pemrosesan data dan konfigurasi model yang akan digunakan dalam penelitian.

2.4 Implementasi

Tahap implementasi berfokus pada proses pelatihan model klasifikasi penyakit daun mangga menggunakan arsitektur YOLOv11s. Proses diawali dengan pemuatan dataset yang telah dibagi menggunakan skema *10-Fold Cross Validation*.



Pada setiap *fold*, *model* dilatih menggunakan data *training* yang telah melalui tahap *pre-processing* dan augmentasi, sementara data *testing* digunakan secara eksklusif untuk evaluasi *model* tanpa perlakuan tambahan. Pelatihan model dilakukan dengan parameter yang telah ditentukan pada tahap perancangan. Selama proses pelatihan, sistem mencatat nilai training loss dan validation loss untuk memantau kestabilan pembelajaran dan mendeteksi potensi overfitting. Proses pelatihan diulang pada setiap *fold* hingga seluruh skema validasi silang selesai dilakukan.

2.5 Pengujian

Tahap pengujian dilakukan untuk mengevaluasi kinerja model yang telah dilatih. Pengujian dilakukan menggunakan data testing pada masing-masing *fold* dengan metode Confusion Matrix. Dari confusion matrix tersebut dihitung metrik evaluasi berupa accuracy, precision, recall, dan F1-score. Metrik-metrik ini digunakan untuk menilai kemampuan model dalam mengklasifikasikan setiap kelas penyakit daun mangga secara tepat dan konsisten. Selain itu, hasil pengujian pada seluruh *fold* dianalisis secara komparatif untuk melihat kestabilan performa model. Evaluasi ini bertujuan untuk memastikan bahwa model tidak hanya memiliki akurasi tinggi, tetapi juga mampu mempertahankan performa yang konsisten pada seluruh skema pengujian.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian Model

Pengujian model klasifikasi penyakit daun mangga dilakukan menggunakan algoritma YOLOv11s dengan skema *10-Fold Cross Validation*, di mana pada setiap *fold* data dibagi menjadi 90% data training dan 10% data *testing*. Proses *image augmentation* hanya diterapkan pada data training untuk mencegah terjadinya data *leakage*, sedangkan data testing digunakan secara murni sebagai data evaluasi. Berdasarkan hasil pengujian, model YOLOv11s menunjukkan performa yang sangat konsisten pada seluruh *fold*. Nilai akurasi yang diperoleh pada setiap *fold* mencapai 1.00 (100%), dengan rata-rata training loss sebesar 0,0979 dan validation loss sebesar 0,0027. Nilai loss yang rendah menunjukkan bahwa model mampu mempelajari pola visual pada data latih secara efektif serta mempertahankan performa yang stabil pada data uji. Selain itu, hasil pelatihan menunjukkan bahwa model mencapai konvergensi pada jumlah epoch yang relatif rendah, yaitu berada pada rentang 5 hingga 18 epoch. Hal ini mengindikasikan bahwa arsitektur YOLOv11s memiliki kemampuan representasi fitur yang kuat, sehingga proses pembelajaran dapat berlangsung secara efisien tanpa memerlukan pelatihan dalam jumlah epoch yang besar.

Tabel 2. Hasil Pengujian Model

Fold	Best Epoch	Accuracy	Training Loss	Validation Loss
Fold 1	8	1.00	0.11213	0.00264
Fold 2	5	1.00	0.15951	0.00681
Fold 3	17	1.00	0.05444	0.00054
Fold 4	13	1.00	0.08322	0.00175
Fold 5	18	1.00	0.05804	0.00058
Fold 6	6	1.00	0.13608	0.00225
Fold 7	16	1.00	0.06194	0.00255
Fold 8	11	1.00	0.06867	0.00185
Fold 9	7	1.00	0.13016	0.00525
Fold 10	7	1.00	0.11492	0.00267

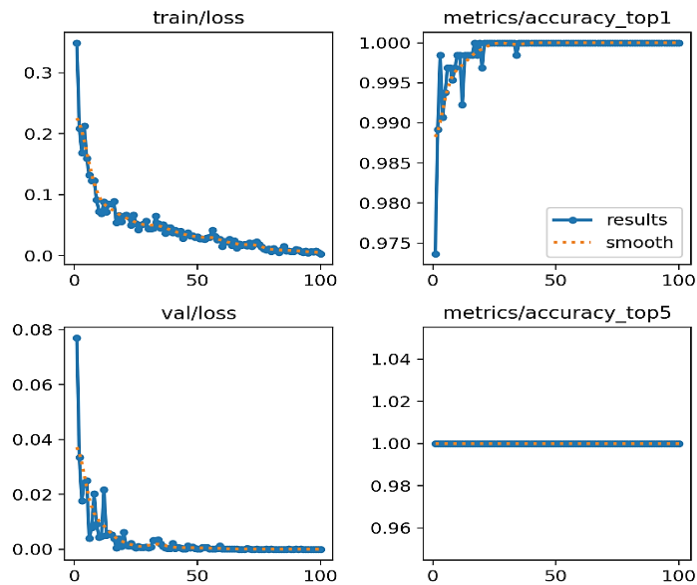
3.2 Analisis Hasil 10-Fold Cross Validation

Tabel hasil pengujian menunjukkan bahwa seluruh *fold* menghasilkan nilai akurasi yang identik, yaitu 100%. Meskipun demikian, pemilihan model terbaik dalam penelitian ini tidak didasarkan pada nilai akurasi, melainkan pada nilai validation loss terendah sebagai indikator kemampuan generalisasi model terhadap data yang tidak dilatih. Berdasarkan kriteria tersebut, Fold 3 dipilih sebagai model terbaik karena memiliki nilai validation loss paling rendah sebesar 0,00054, yang menunjukkan tingkat kesalahan prediksi paling kecil dibandingkan *fold* lainnya. Pendekatan ini penting untuk menghindari bias evaluasi yang hanya berfokus pada akurasi, terutama ketika seluruh *fold* menghasilkan nilai akurasi yang sama. Dengan mempertimbangkan validation loss, pemilihan model terbaik menjadi lebih objektif dan mencerminkan kestabilan performa model dalam menghadapi variasi data.

3.3 Analisis Grafik Pelatihan Model Terbaik (Fold 3)

Pada Gambar 3 hasil pelatihan pada *Fold 3*, model menunjukkan performa yang sangat optimal dan stabil selama 100 *epoch* pelatihan. Pada grafik *loss*, baik *train/loss* maupun *val/loss* mengalami penurunan yang tajam pada 20 *epoch* pertama dan mencapai titik konvergensi mendekati nilai 0 tanpa menunjukkan gejala *overfitting* atau *underfitting*. Sejalan dengan itu, grafik akurasi *metrics/accuracy_top1* menunjukkan peningkatan yang konsisten hingga mencapai nilai maksimal 1.00 (100%), sementara *metrics/accuracy_top5* telah menunjukkan nilai sempurna sejak awal fase pelatihan. Meskipun seluruh *fold* menghasilkan nilai akurasi yang sama, pemilihan model terbaik tidak didasarkan pada

akurasi semata. Dalam penelitian ini, kriteria pemilihan model terbaik ditentukan berdasarkan nilai validation loss terendah, yang merepresentasikan kemampuan generalisasi model terhadap data yang tidak dilatih. Berdasarkan hasil pengujian, Fold 3 dipilih sebagai model terbaik karena memiliki nilai validation loss terendah, yaitu sebesar 0,00054. Nilai ini menunjukkan bahwa model pada Fold 3 memiliki tingkat kesalahan prediksi paling kecil pada data validasi dibandingkan fold lainnya, sehingga dianggap paling stabil dan optimal untuk merepresentasikan performa model YOLOv11s.

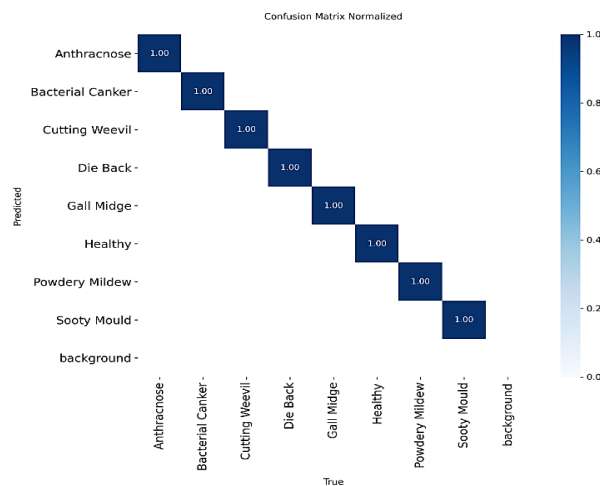


Gambar 3. Grafik Pelatihan Model Fold 3

Pada Gambar 3 dapat dilihat bahwa hasil pelatihan pada *Fold 3*, model menunjukkan performa yang sangat optimal dan stabil selama 100 *epoch* pelatihan.

3.4 Hasil Pelatihan Model Terbaik

Pada bagian ini akan ditampilkan hasil pelatihan model terbaik dari 10 *fold* dari pengujian YOLOV11 yaitu *fold 3* dengan menampilkan grafik dan hasil confusion matrix.



Gambar 4. Confusion Matrix Normalized Fold 3

Pada Gambar 4 hasil pengujian model melalui *Confusion Matrix* yang telah dinormalisasi menunjukkan performa klasifikasi yang sempurna dengan tingkat akurasi 100% pada seluruh kelas target. Matriks diagonal yang bernilai 1.00 pada seluruh kelas mengindikasikan bahwa setiap data uji diklasifikasikan dengan tepat sesuai dengan label sebenarnya. Tidak ditemukan adanya *misclassification* atau kesalahan prediksi antar kelas, yang dibuktikan dengan nilai 0.00 pada area di luar garis diagonal utama. Hasil ini memperkuat temuan pada grafik pelatihan sebelumnya, yang menunjukkan bahwa model tidak hanya konvergen secara stabil namun juga mampu membedakan karakteristik spesifik dari setiap jenis penyakit tanaman dengan akurasi pada dataset pengujian ini. Perolehan nilai akurasi 100% pada seluruh fold pengujian merupakan hasil yang jarang ditemukan pada pengolahan citra alami, khususnya pada kondisi lapangan. Namun, hasil ini dapat dijelaskan oleh karakteristik dataset *Mango Leaf Disease* yang digunakan, di mana sebagian besar citra diambil dalam kondisi pencahayaan yang relatif seragam, latar belakang



yang bersih, serta objek daun yang terpusat dengan jelas. Kondisi ini menyebabkan perbedaan antar kelas penyakit menjadi sangat kontras dan mudah dipelajari oleh model YOLOv11 yang memiliki kapasitas representasi fitur yang tinggi. Oleh karena itu, hasil ini tidak serta-merta menunjukkan bahwa model akan selalu mencapai performa serupa pada kondisi lapangan yang lebih kompleks, melainkan mencerminkan performa optimal pada dataset terkontrol yang digunakan dalam penelitian ini.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa algoritma YOLOv11s mampu melakukan klasifikasi penyakit daun mangga dengan performa yang sangat baik pada dataset yang digunakan. Model menunjukkan kestabilan kinerja pada seluruh skema pengujian menggunakan *10-Fold Cross Validation*, dengan nilai akurasi, presisi, *recall*, dan *F1-score* yang tinggi. Penerapan tahapan *pre-processing*, *image augmentation* yang terkontrol, serta *hyperparameter tuning* berkontribusi terhadap kemampuan model dalam mengekstraksi fitur penyakit daun secara efektif. Namun demikian, hasil yang sangat tinggi ini juga dipengaruhi oleh karakteristik dataset yang relatif terstandarisasi, sehingga generalisasi model terhadap kondisi lapangan yang lebih kompleks masih perlu diuji lebih lanjut. Oleh karena itu, penelitian selanjutnya disarankan menggunakan dataset dengan variasi pencahayaan dan latar belakang yang lebih beragam agar sistem yang dikembangkan semakin robust dan aplikatif di lingkungan nyata. Secara khusus, kontribusi utama penelitian ini terletak pada penyediaan evaluasi komprehensif algoritma YOLOv11s untuk klasifikasi penyakit daun mangga dengan pendekatan *10-Fold Cross Validation*, analisis kestabilan model berbasis *validation loss*, serta pembuktian potensi penerapan model pada sistem deteksi *real-time* dengan efisiensi komputasi yang tinggi. Kontribusi ini diharapkan dapat menjadi referensi bagi pengembangan sistem visi komputer di bidang pertanian presisi, khususnya untuk deteksi dini penyakit tanaman mangga.

REFERENCES

- Abade, A., Ferreira, P. A., & de Barros Vidal, F. (2021). Plant diseases recognition on images using convolutional neural networks: A systematic review. *Computers and Electronics in Agriculture*, 185, 106125. <https://doi.org/10.1016/j.compag.2021.106125>
- Ahmed, S. I., Ibrahim, M., Nadim, Md., Rahman, Md. M., Shejunti, M. M., Jabid, T., & Ali, Md. S. (2022). *MangoLeafBD: A Comprehensive Image Dataset to Classify Diseased and Healthy Mango Leaves*. <https://doi.org/https://doi.org/10.48550/arXiv.2209.02377>
- Aldakheel, E. A., Zakariah, M., & Alabdallal, A. H. (2024). Detection and identification of plant leaf diseases using YOLOv4. *Frontiers in Plant Science*, 15. <https://doi.org/10.3389/fpls.2024.1355941>
- Ali, S., Ibrahim, M., Sarder Iftekhar, Nadim, Md., Mizanur, M. R., Shejunti, M. M., & Jabid, T. (2022). *MangoLeafBD Dataset*. Mendeley. <https://doi.org/10.17632/HXSNVWTY3R>
- Arcila-Diaz, L., Mejia-Cabrera, H. I., & Arcila-Diaz, J. (2024). Estimation of Mango Fruit Production Using Image Analysis and Machine Learning Algorithms. *Informatics*, 11(4). <https://doi.org/10.3390/informatics11040087>
- Arti, I. M., Asnur, P., Kurniasih, R., & Ramdan, E. P. (2022). Identification, Pathogenesis and Virulence Test of Fungus Causes Postharvest Disease of Gedong Gincu Mango from Pal Market, Cimanggis, Depok. *Jurnal Pembelajaran Dan Biologi Nukleus*, 8(2), 236–246. <https://doi.org/10.36987/jpbn.v8i2.2628>
- Ashwinkumar, S., Rajagopal, S., Manimaran, V., & Jegajothi, B. (2022). Automated plant leaf disease detection and classification using optimal MobileNet based convolutional neural networks. *Materials Today: Proceedings*, 51, 480–487. <https://doi.org/10.1016/j.matpr.2021.05.584>
- Caldeira, R. F., Santiago, W. E., & Teruel, B. (2021). Identification of Cotton Leaf Lesions Using Deep Learning Techniques. *Sensors*, 21(9), 3169. <https://doi.org/10.3390/s21093169>
- Chowdhury, M. E. H., Rahman, T., Khandakar, A., Ayari, M. A., Khan, A. U., Khan, M. S., Al-Emadi, N., Reaz, M. B. I., Islam, M. T., & Ali, S. H. M. (2021). Automatic and Reliable Leaf Disease Detection Using Deep Learning Techniques. *AgriEngineering*, 3(2), 294–312. <https://doi.org/10.3390/agriengineering3020020>
- Han, Y., Chen, L., & Hou, W. (2023). Study of a Layered Plate Girder Element of Composite Materials and Its Applications. *Applied Sciences*, 13(11), 6545. <https://doi.org/10.3390/app13116545>
- Harmiansyah, H., Oviana, E. T., Alpaizon, R., Khalifah, D. P., & Dwirotnama, P. (2024). Sistem Deteksi Hama dan Penyakit Tanaman Mangga (*Mangifera indica* L.) Berbasis Deep Learning Menggunakan Model Pra Latih YOLOv5. *Agrikultura*, 35(1), 151. <https://doi.org/10.24198/agrikultura.v35i1.53834>
- Jung, M., Song, J. S., Shin, A.-Y., Choi, B., Go, S., Kwon, S.-Y., Park, J., Park, S. G., & Kim, Y.-M. (2023). Construction of deep learning-based disease detection model in plants. *Scientific Reports*, 13(1), 7331. <https://doi.org/10.1038/s41598-023-34549-2>
- Li, T., Zhang, L., & Lin, J. (2024). Precision agriculture with YOLO-Leaf: advanced methods for detecting apple leaf diseases. *Frontiers in Plant Science*, 15. <https://doi.org/10.3389/fpls.2024.1452502>
- Liu, J., & Wang, X. (2021). Plant diseases and pests detection based on deep learning: a review. *Plant Methods*, 17(1), 22. <https://doi.org/10.1186/s13007-021-00722-9>
- Perumal, V. K., T, S., P R, S., & S, D. (2024). CNN based plant disease identification using PYNQ FPGA. *Systems and Soft Computing*, 6, 200088. <https://doi.org/10.1016/j.sasc.2024.200088>



- Preeya V, A., Raja, S. P., Dhanalakshmi, B. K., Gururaj, H., Ravi, V., & Ravi, P. (2024). Perceptual Pigeon Galvanized Optimization of Multi-objective CNN on the Identification and Classification of Mango Leaves Disease. *The Open Agriculture Journal*, 18(1). <https://doi.org/10.2174/0118743315331264240917073431>
- Sudhesh, V., S., P., S. K., & O.K., S. (2023). AI based rice leaf disease identification enhanced by Dynamic Mode Decomposition. *Engineering Applications of Artificial Intelligence*, 120, 105836. <https://doi.org/10.1016/j.engappai.2023.105836>
- Wang, X., & Liu, J. (2024). Vegetable disease detection using an improved YOLOv8 algorithm in the greenhouse plant environment. *Scientific Reports*, 14(1), 4261. <https://doi.org/10.1038/s41598-024-54540-9>
- Yang, S., Yao, J., & Teng, G. (2024). Corn Leaf Spot Disease Recognition Based on Improved YOLOv8. *Agriculture*, 14(5), 666. <https://doi.org/10.3390/agriculture14050666>
- Yao, J., Wang, Y., Xiang, Y., Yang, J., Zhu, Y., Li, X., Li, S., Zhang, J., & Gong, G. (2022). Two-Stage Detection Algorithm for Kiwifruit Leaf Diseases Based on Deep Learning. *Plants*, 11(6), 768. <https://doi.org/10.3390/plants11060768>