

Analisis Perbandingan Kinerja Model YOLO11 dan YOLOv8 dalam Identifikasi Penyakit pada Daun Tomat

Muhammad Arif Kholis Majid¹, Dhani Ariatmanto²

^{1,2}Magister Informatika, Universitas Amikom Yogyakarta,

Jl. Ring Road Utara, Ngringin, Condongcatat, Kec. Depok, Kab. Sleman, Daerah Istimewa Yogyakarta, Indonesia

¹arifmajid@students.amikom.ac.id (penulis korespondensi)

²dhaniari@amikom.ac.id

Intisari— Penyakit pada daun tomat dapat mengurangi kualitas dan kuantitas hasil pertanian serta memengaruhi harga pasar. Penelitian ini membandingkan efektivitas model YOLO11 dan YOLOv8 dalam mendeteksi penyakit pada daun tomat dengan model berbasis CNN tradisional seperti VGG-16 dan Inception-V3. Hasil menunjukkan bahwa model YOLO11 memberikan akurasi terbaik 99.4%, diikuti oleh YOLOv8 dengan 98.5%, keduanya unggul dalam deteksi real-time. Model berbasis CNN seperti VGG-16 dan Inception-V3 memiliki akurasi tinggi (99% dan 93.8%), namun lebih lambat dalam komputasi. Ensemble model VGG-16 dan NASNet Mobile mencapai akurasi 98.7%, namun sedikit lebih rendah dari YOLO11. Model YOLO lebih efisien dalam hal kecepatan deteksi, menjadikannya pilihan yang lebih baik untuk aplikasi di lapangan. Penelitian ini menunjukkan bahwa YOLO11 menawarkan kombinasi terbaik antara akurasi dan kecepatan deteksi untuk sistem deteksi penyakit tanaman secara real-time.

Kata Kunci: YOLO, deteksi penyakit tanaman, daun tomat, YOLOv8, YOLO11, CNN

Abstract— Diseases on tomato leaves can reduce the quality and quantity of agricultural yields, as well as affect market prices. This study compares the effectiveness of the YOLO11 and YOLOv8 models in detecting diseases on tomato leaves with traditional CNN-based models such as VGG-16 and Inception-V3. The results show that the YOLO11 model provides the best accuracy of 99.4%, followed by YOLOv8 with 98.5%, both excelling in real-time detection. CNN-based models like VGG-16 and Inception-V3 have high accuracy (99% and 93.8%), but are slower in computation. The ensemble model of VGG-16 and NASNet Mobile achieves an accuracy of 98.7%, but is slightly lower than YOLO11. The YOLO model is more efficient in detection speed, making it a better choice for field applications. This study shows that YOLO11 offers the best combination of accuracy and detection speed for a real-time plant disease detection system.

Keywords—: YOLO, plant disease detection, tomato leaves, YOLOv8, YOLO11, CNN

I. PENDAHULUAN

Berdasarkan data dari Badan Pusat Statistik (BPS) pada 2024, Indonesia memiliki luas lahan pertanian untuk budidaya tomat sekitar 58.782,74 hektar. Selain itu, total hasil produksi tomat di Indonesia tercatat mencapai 11.466.079,40 kuintal [1]. Angka ini menggambarkan potensi besar sektor pertanian hortikultura di Indonesia yang berperan penting dalam ketahanan pangan serta kesejahteraan petani. Namun, di Desa Jeprono, Kecamatan Karangbun, Kabupaten Karanganyar, meskipun harga tomat naik, petani menghadapi gagal panen akibat serangan hama dan penyakit yang tidak terdeteksi atau terkendali dengan baik. Penggunaan pestisida kimia yang berlebihan dan tidak tepat sasaran menambah biaya produksi dan merusak lingkungan, serta mengancam kesehatan. Teknologi untuk membantu petani dalam mengidentifikasi hama masih terbatas, sehingga produktivitas tomat terganggu dan pendapatan petani terancam. Keberlanjutan usaha tani di desa ini menjadi tantangan karena masalah hama dan penyakit yang tidak teratasi dengan efektif [2].

Penyakit pada daun tomat, mosaic virus, target spot, bacterial spot, dan tomato yellow leaf curl virus yang dapat

mengurangi kualitas dan kuantitas hasil pertanian, serta mempengaruhi harga pasar [3]. Penyakit ini cepat menyebar jika tidak segera diatasi, sehingga deteksi dini sangat penting. Dengan kemajuan teknologi, kecerdasan buatan (AI) semakin banyak digunakan untuk mendeteksi penyakit pada tanaman, khususnya melalui model deep learning seperti YOLO (You Only Look Once). YOLO11 dan YOLOv8, versi terbaru dari model ini, menawarkan peningkatan akurasi, kecepatan, dan efisiensi komputasi untuk deteksi penyakit pada daun tomat secara real-time [4].

YOLO11 memiliki beberapa keunggulan teoritis dibandingkan YOLOv8, antara lain arsitektur yang disempurnakan dengan menggunakan blok C3k2 dan SPPF yang lebih efisien dalam ekstraksi fitur multi-skala, implementasi attention mechanism melalui C2PSA (Cross Stage Partial with Spatial Attention) untuk fokus pada fitur yang lebih relevan, dukungan yang lebih baik untuk multi-task learning dalam deteksi objek, segmentasi, dan klasifikasi secara simultan, serta optimasi komputasi yang meningkatkan efisiensi penggunaan memori dan kecepatan inferensi [5].

Deteksi penyakit tanaman telah mengembangkan berbagai pendekatan dengan karakteristik yang beragam. Pada penelitian

sebelumnya [6], menggunakan model CNN dengan arsitektur VGG-16, untuk mengklasifikasikan penyakit pada daun tomat. Model ini mencapai akurasi pelatihan 99% akurasi pengujian 91% dan validasi 92%. Namun, pendekatan berbasis CNN sering memerlukan waktu komputasi yang lebih lama, terutama untuk analisis citra real-time. Sebaliknya, model YOLO11 dan YOLOv8 dirancang untuk deteksi objek real-time, menjadikannya lebih cepat dan efisien tanpa mengorbankan akurasi [4]. Kedua model ini juga lebih mampu menangani variasi pencahayaan, latar belakang, dan sudut pandang [4].

Perbandingan empiris antara YOLO11 dan YOLOv8 dalam deteksi penyakit daun tomat masih terbatas. Penelitian sebelumnya lebih fokus pada penggunaan satu model atau perbandingan dengan CNN tradisional, tanpa membandingkan kedua versi YOLO terbaru ini dalam kondisi yang sama. Kesenjangan penelitian mencakup kurangnya perbandingan langsung antara keduanya dengan dataset dan eksperimen yang serupa, serta evaluasi komprehensif yang mempertimbangkan akurasi, kecepatan deteksi, efisiensi komputasi, dan kemampuan generalisasi. Oleh karena itu, penelitian ini bertujuan untuk membandingkan kinerja YOLO11 dan YOLOv8 dalam deteksi penyakit daun tomat dengan dataset dan eksperimen terkontrol, serta mengevaluasi efisiensi dan kinerja komprehensifnya untuk aplikasi deteksi penyakit tanaman real-time. Penelitian ini diharapkan dapat memberikan kontribusi dalam pemilihan model terbaik untuk sistem deteksi penyakit tanaman dalam praktik pertanian modern.

II. STUDI PUSTAKA

Pada penelitian Adias Pradana dkk, menggunakan model CNN dengan arsitektur VGG-16 digunakan untuk mengklasifikasikan penyakit pada daun tomat [6]. Model ini berhasil mencapai akurasi 99% pada data pelatihan, sementara akurasi pada data pengujian tercatat 91% dan pada data validasi mencapai 92%. Penelitian ini lebih fokus pada penggunaan model CNN untuk klasifikasi gambar, sementara penelitian yang akan dilakukan mengandalkan YOLO untuk deteksi objek real-time yang lebih cepat dan efisien dalam akurasi deteksi penyakit pada daun tomat.


Penelitian Andi Nurdin dkk, Metode Convolutional Neural Network (CNN) dengan transfer learning menggunakan Inception-V3 dalam penelitian ini menunjukkan bahwa penggunaan optimizer Adam, SGD, dan RMSProp menghasilkan performa yang berbeda. Dari hasil eksperimen, optimizer Adam terbukti memberikan hasil terbaik, dengan model menunjukkan performa yang stabil dan mencapai akurasi tertinggi sebesar 93,8% [7]. Perbandingan penelitian ini terletak pada akurasi dan model yang digunakan apakah YOLO dapat mengungguli CNN dalam deteksi penyakit pada daun tomat.

Penelitian Pandiyaraju dkk, mengembangkan metode baru untuk klasifikasi penyakit daun tomat menggunakan model ensemble yang dipadukan dengan teknik optimasi berbasis kecerdasan kelompok [8]. Deteksi dini penyakit pada tanaman tomat penting untuk meningkatkan hasil panen. Model ensemble ini menggabungkan fungsi exponential moving average dan optimisasi berbobot gradien, serta

mengintegrasikan pelatihan fine-tuned dari VGG-16 dan NASNet Mobile. Dataset yang digunakan terdiri dari 10.000 gambar daun tomat dari sembilan jenis penyakit, dengan 1.000 gambar untuk pengujian. Hasilnya menunjukkan peningkatan kinerja dengan akurasi 98,7%, presisi 97,9%, recall 98,6%, ROC 99,97%, dan F1-score 98,7%. Perbedaan antara penelitian ini dengan penelitian yang akan dilakukan terletak pada metode yang digunakan menggunakan YOLO untuk deteksi objek real-time. Selain itu, penelitian yang akan dilakukan bisa meningkatkan akurasi dengan mengoptimalkan parameter YOLO atau mencoba menerapkan versi YOLO yang lebih baru seperti YOLO11 dan YOLOv8, yang lebih efisien dan akurat dalam klasifikasi penyakit pada daun tomat.

III. METODOLOGI PENELITIAN

Penelitian ini termasuk dalam penelitian kuantitatif, karena mengukur kinerja model YOLO11 dan YOLOv8 menggunakan data numerik, seperti akurasi, kecepatan deteksi, precision, recall, dan F1-score, yang dianalisis secara statistik. Gambar 1 menunjukkan alur penelitian.



Gambar 1. Alur Penelitian

Penelitian ini dimulai dengan pengumpulan dataset penyakit daun tomat, yang berisi gambar daun tomat yang terinfeksi berbagai jenis penyakit. Dataset tersebut kemudian dibagi menjadi dua bagian: data pelatihan (90,91%) yang digunakan untuk melatih model dan data validasi (9,09%) yang digunakan untuk memvalidasi model selama proses pelatihan. Pada proses

pelatihan model, data pelatihan digunakan untuk mengajarkan model mengenali pola dari gambar daun tomat yang telah diberi label, seperti jenis penyakit yang ada. Model akan melalui beberapa iterasi di mana ia mencoba memprediksi label berdasarkan gambar dan kemudian menyesuaikan parameter internal untuk mengurangi kesalahan. Data validasi digunakan untuk memantau kinerja model selama pelatihan, memastikan bahwa model tidak mengalami overfitting atau underfitting. Data ini membantu menilai kemampuan model dalam mengklasifikasikan data yang belum dilihat sebelumnya.

Selanjutnya, dilakukan klasifikasi penyakit dengan YOLO11 menggunakan data pelatihan untuk mengajarkan model mengenali penyakit pada daun tomat. Proses yang sama juga dilakukan dengan YOLOv8, yang merupakan model deteksi objek lainnya, untuk membandingkan kinerjanya.

Setelah klasifikasi dilakukan, tahap evaluasi dilaksanakan untuk mengukur kinerja kedua model (YOLO11 dan YOLOv8). Evaluasi ini bertujuan untuk menilai keakuratan, kecepatan deteksi, dan efisiensi komputasi dari kedua model dalam mendeteksi penyakit pada daun tomat. Evaluasi dilakukan menggunakan akurasi untuk mengukur seberapa sering model membuat prediksi yang benar. Akurasi dihitung dengan membagi jumlah prediksi yang benar dengan total prediksi yang dibuat.

Berdasarkan hasil evaluasi, kesimpulan diambil mengenai model mana yang lebih efektif dalam melakukan deteksi penyakit. Proses ini berakhir setelah kesimpulan diambil, dan penelitian dianggap selesai.

Dengan demikian, alur penelitian ini menggabungkan pembagian dataset, pelatihan model dengan YOLO11 dan YOLOv8, serta evaluasi untuk menentukan model terbaik dalam mendeteksi penyakit daun tomat.

3.1 Pengumpulan Data

3.1.1 Studi Pustaka

Studi pustaka adalah kajian terhadap literatur atau penelitian sebelumnya yang relevan dengan topik penelitian, untuk memahami teori, konsep, dan temuan yang ada serta mengidentifikasi kesenjangan penelitian [9].

Studi pustaka ini mengkaji literatur terkait deteksi penyakit daun tomat menggunakan model deep learning, khususnya YOLO. Pencarian literatur dilakukan melalui basis data internasional dan nasional, dengan kata kunci seperti "YOLO", "YOLOv8", "YOLO11", dan "plant disease detection". Kriteria inklusi meliputi artikel yang diterbitkan antara 2020-2024, jurnal internasional bereputasi atau jurnal nasional terakreditasi, dan penelitian yang menggunakan metodologi eksperimental dengan evaluasi kuantitatif.

Penelitian sebelumnya menunjukkan berbagai pendekatan dalam deteksi penyakit daun tomat menggunakan deep learning. Adias Pradana et al. dalam publikasi mereka di Jurnal Riset Inovasi Bidang Informatika dan Pendidikan Informatika menggunakan model CNN dengan arsitektur VGG-16 untuk mengklasifikasikan penyakit pada daun tomat, dengan hasil akurasi 99% pada data pelatihan, 91% pada data pengujian, dan 92% pada data validasi [6]. Penelitian Nurdin et al., dalam artikel konferensi, menggunakan CNN dengan transfer learning

Inception-V3 dan optimizer Adam, mencapai akurasi tertinggi 93,8% [7]. Penelitian Pandiyaraju V et al., yang dipublikasikan di Front Plant Science, mengembangkan model ensemble dengan akurasi 98,7%, presisi 97,9%, recall 98,6%, ROC 99,97%, dan F1-score 98,7% [8]. Penelitian Zayani et al., dalam publikasinya di Engineering, Technology and Applied Science Research menggunakan YOLOv8 untuk deteksi penyakit daun tomat, meskipun penelitian ini belum membandingkan dengan versi YOLO yang lebih baru seperti YOLO11 [3]. Sementara itu, Penelitian Sapkota et al. dalam preprint mereka di arXiv melakukan evaluasi berbagai versi YOLO, termasuk YOLO11, YOLOv10, YOLOv9, dan YOLOv8, untuk deteksi buah dalam kebun kompleks, memberikan insight mengenai performa relatif antar versi YOLO, meskipun aplikasi yang digunakan berbeda dari deteksi penyakit daun [4].

Dari review literatur yang telah dilakukan, dapat disimpulkan bahwa sebagian besar penelitian terdahulu menggunakan jurnal nasional terakreditasi dan jurnal internasional bereputasi sebagai media publikasi. Namun, masih terdapat kesenjangan dalam hal perbandingan langsung antara YOLO11 dan YOLOv8 khusus untuk deteksi penyakit daun tomat, yang menjadi fokus utama penelitian ini. Penelitian yang akan dilakukan bertujuan untuk mengisi kesenjangan tersebut dengan melakukan perbandingan empiris yang komprehensif antara kedua model menggunakan dataset dan metodologi yang sama.

3.2 Dataset

Dalam penelitian ini, dataset yang digunakan diambil dari Kaggle dengan nama Tomato Leaf Diseases Detection [10]. Semua gambar yang ada dalam dataset ini disimpan dalam format JPG. Dataset ini terdiri dari 11.000 citra penyakit daun tomat yang terbagi dalam 10 kelas.

Dataset penelitian ini mencakup sepuluh kategori yang terdiri dari sembilan jenis penyakit dan satu kategori sehat. Tomato Mosaic Virus ditandai dengan pola mozaik berwarna hijau muda dan hijau gelap yang tersebar tidak merata pada permukaan daun, disertai dengan deformasi dan kerutan pada daun. Target Spot dikarakterisasi dengan bercak bulat berwarna coklat yang memiliki pola cincin konsentris menyerupai target panah, biasanya dimulai dari tepi daun. Bacterial Spot menunjukkan bercak-bercak kecil berwarna coklat kehitaman dengan tepi kuning yang tersebar secara acak di seluruh permukaan daun. Tomato Yellow Leaf Curl Virus menyebabkan daun menguning, menggulung ke atas, dan pertumbuhan tanaman menjadi kerdil dengan daun yang mengalami deformasi berat.

Late Blight ditandai dengan bercak besar berwarna hijau kecoklatan dengan tepi putih keabu-abuan yang dapat menyebar dengan cepat dan menyebabkan pembusukan pada daun. Leaf Mold memiliki karakteristik bercak kuning pada permukaan atas daun yang berkembang menjadi area nekrotik berwarna coklat, sering disertai dengan pertumbuhan jamur berwarna hijau pada bagian bawah daun. Early Blight diidentifikasi melalui bercak coklat berbentuk target dengan pola cincin konsentris yang jelas, biasanya dimulai dari daun

tua bagian bawah tanaman. Spider Mites Two-Spotted Spider Mite menyebabkan bintik-bintik kecil kuning yang tersebar di seluruh permukaan daun, memberikan tampilan berbronze atau keperakan pada daun yang terinfeksi parah. Septoria Leaf Spot dikarakterisasi dengan bercak kecil bulat berwarna abu-abu dengan tepi gelap yang biasanya memiliki titik hitam kecil di tengahnya. Sedangkan Tomato Healthy menunjukkan daun dengan warna hijau normal, tekstur sehat, dan tidak ada tanda-tanda bercak, perubahan warna, atau deformasi yang mengindikasikan adanya penyakit. Tabel 1 berisi informasi dataset.

TABEL I
INFORMASI DATASET

No.	Penyakit Daun Tomat	Jumlah
1.	Tomato Mosaic Virus	1100
2.	Target Spot	1100
3.	Bacterial Spot	1100
4.	Tomato Yellow Leaf Curl Virus	1100
5.	Late Blight	1100
6.	Leaf Mold	1100
7.	Early Blight	1100
8.	Spider Mites Two-Spotted Spider Mite	1100
9.	Tomato Healthy	1100
10.	Septoria Leaf Spot	1100

3.3 Split Dataset

Split dataset adalah proses membagi dataset menjadi beberapa bagian yang digunakan untuk tujuan berbeda dalam pelatihan model pembelajaran mesin [11]. Proses ini bertujuan memastikan model yang dilatih dapat diuji dengan data yang belum pernah dilihat sebelumnya, sehingga memberikan estimasi performa yang objektif terhadap kemampuan generalisasi model [12]. Bagian-bagian yang dihasilkan dari proses split ini digunakan untuk pelatihan model, validasi selama pelatihan, dan pengujian setelah pelatihan untuk menilai seberapa baik model bekerja pada data yang tidak dikenalnya [13].


Proses ini menggunakan teknik stratified random sampling untuk memastikan distribusi yang seimbang dari setiap kelas penyakit dalam data pelatihan dan validasi. Dataset yang terdiri dari 11.000 gambar (1.100 gambar per kelas untuk 10 kelas penyakit) akan diproses terlebih dahulu untuk memastikan kualitas dan konsistensi format gambar. Setiap gambar akan diberikan label sesuai dengan jenis penyakitnya dan disusun dalam struktur direktori berdasarkan kelas.

Pembagian dataset akan dilakukan dengan rasio 90:10 untuk training dan validation set, yang dipilih berdasarkan ukuran dataset yang besar, memungkinkan alokasi 10% untuk validasi dengan jumlah 1.000 gambar sudah cukup untuk evaluasi yang representatif, sementara 90% untuk training (10.000 gambar) memberikan data yang cukup untuk model mempelajari pola yang kompleks. Proses sampling akan dilakukan dengan menggunakan random seed yang tetap (seed=42) untuk memastikan hasil yang reproducible. Setelah pembagian, verifikasi akan dilakukan untuk memastikan distribusi kelas

pada data training dan validasi proporsional tanpa bias terhadap kelas tertentu, guna menghindari masalah class imbalance yang dapat mempengaruhi performa model [14]. Dengan cara ini, pembagian dataset diharapkan dapat memaksimalkan efektivitas pelatihan model dan memberikan evaluasi yang objektif terhadap kemampuan kedua model dalam mendeteksi penyakit daun tomat [15].

3.4 YOLO

YOLO (You Only Look Once) adalah algoritma deteksi objek yang sangat efisien dalam bidang computer vision. YOLO dirancang untuk mendeteksi objek dalam gambar atau video secara real-time dengan kecepatan tinggi dan akurasi yang cukup baik [16]. Keistimewaannya terletak pada cara kerjanya yang berbeda dengan metode deteksi objek lainnya, di mana YOLO hanya memproses gambar sekali dan langsung menghasilkan hasil deteksi [17]. Gambar 2 adalah visualisasi arsitektur pada YOLO secara umum



Gambar 2. Arsitektur YOLO

Arsitektur YOLO (You Only Look Once) yang ditunjukkan dalam gambar ini dimulai dengan input layer yang menerima gambar berukuran 448x448x3. Gambar ini kemudian diproses melalui serangkaian convolutional layers, yang bertugas mengekstraksi fitur-fitur penting seperti tepi, tekstur, dan pola objek dalam gambar. Setelah itu, maxpool layers digunakan untuk mengurangi dimensi spasial gambar dan mengurangi jumlah parameter dalam jaringan, sehingga mempercepat pemrosesan.

Setelah lapisan konvolusi dan pooling, data fitur yang telah diekstraksi diteruskan ke fully connected layers, yang menghubungkan semua fitur yang dipelajari untuk menghasilkan prediksi [18]. Lapisan output yang terakhir menghasilkan informasi seperti bounding box (lokasi objek), kelas objek, dan confidence score, yang digunakan untuk mendeteksi objek dalam gambar [4].

Dengan struktur ini, YOLO melakukan deteksi objek dan klasifikasi secara end-to-end, memungkinkan model untuk mendeteksi dan mengklasifikasikan objek dalam gambar secara cepat dan efisien dalam satu langkah [19].

YOLOv8 memperkenalkan anchor-free detection, optimasi pada backbone dan neck dengan CSPNet dan FPN+PAN, serta meningkatkan kecepatan, akurasi, dan efisiensi untuk deteksi objek real-time pada perangkat dengan sumber daya terbatas, terutama dalam mendeteksi objek kecil dan mengatasi variasi pencahayaan serta latar belakang [20].

YOLO11 adalah versi terbaru dari model deteksi objek yang menawarkan kecepatan, akurasi, dan efisiensi lebih baik

dibandingkan versi sebelumnya [21]. YOLO11 menggunakan blok C3k2 dan SPPF untuk deteksi objek yang lebih baik pada berbagai skala, serta C2PSA untuk fokus pada fitur penting dalam gambar. Model ini mendukung multi-task learning, termasuk deteksi objek, segmentasi, dan klasifikasi [4].

3.5 Evaluasi

Dalam penelitian ini, evaluasi kinerja model YOLO11 dan YOLOv8 untuk deteksi penyakit pada daun tomat dilakukan dengan menggunakan Confusion Matrix. Confusion matrix adalah alat evaluasi yang digunakan untuk mengukur kinerja model klasifikasi dengan membandingkan prediksi model terhadap nilai aktual [20]. Tabel 2 berisi confusion matrix.

TABEL II
CONFUSION MATRIX

Actual	Predicted	
	True	False
True	TP	FN
False	FP	TN

3.5.1 Akurasi

Mengukur seberapa banyak prediksi yang benar dilakukan oleh model. Akurasi = $\frac{TP+FP}{TP+FP+FN+TN}$ (1)

3.5.2 Presisi

Mengukur seberapa banyak prediksi positif yang benar-benar positif. Presisi = $\frac{TP}{TP+FP}$ (2)

3.5.3 Recall

Mengukur seberapa banyak kasus positif yang berhasil dideteksi. Recall = $\frac{TP}{FP+FN}$ (3)

3.5.4 F1-Score

Harmonik rata-rata antara precision dan recall, memberikan gambaran keseimbangan antara keduanya.

$$F1\ Score = \frac{2 * Recall * Precision}{Recall + Precision} \quad (4)$$

IV. HASIL DAN PEMBAHASAN

4.1 Split Dataset

Dalam penelitian ini, dataset yang terdiri dari 11.000 gambar penyakit daun tomat, yang mencakup 10 kelas penyakit yang berbeda, dibagi menjadi dua bagian utama. Sebanyak 10.000 gambar (90,91%) digunakan untuk data pelatihan (train), yang bertujuan untuk melatih model agar dapat mengenali dan mengklasifikasikan berbagai jenis penyakit yang menyerang daun tomat. Sementara itu, 1.000 gambar (9,09%) digunakan sebagai data validasi (val) untuk mengevaluasi kinerja model yang telah dilatih. Data validasi ini memainkan peran penting untuk mengukur kemampuan model dalam menggeneralisasi, yaitu kemampuan model untuk melakukan prediksi dengan baik pada data yang belum pernah dilihat sebelumnya, yang berasal dari distribusi yang sama dengan data pelatihan.

Pembagian ini dirancang untuk memaksimalkan efektivitas pelatihan model sambil menjaga keseimbangan dalam proses evaluasi. Dengan menggunakan data pelatihan yang cukup besar, model memiliki kesempatan yang lebih baik untuk

belajar dari variasi dalam data. Sementara itu, data validasi yang terpisah dari data pelatihan memastikan bahwa model tidak hanya menghafal data yang dilatih (overfitting), tetapi juga dapat mengaplikasikan apa yang dipelajari pada data baru yang serupa.

Hasil pembagian dataset menunjukkan distribusi yang seimbang untuk setiap kelas penyakit, dengan setiap kelas memiliki 1.000 gambar untuk pelatihan dan 100 gambar untuk validasi. Pembagian ini berhasil memberikan gambaran yang akurat tentang kinerja model dalam deteksi penyakit daun tomat dan membuktikan bahwa model dapat diterapkan dengan baik pada situasi dunia nyata. Tabel 3 berisi hasil split dataset.

TABEL III
HASIL SPLIT DATASET

No.	Penyakit Daun Tomat	Jumlah Data Train	Jumlah Data Val
1.	Tomato Mosaic Virus	1000	100
2.	Target Spot	1000	100
3.	Bacterial Spot	1000	100
4.	Tomato Yellow Leaf Curl Virus	1000	100
5.	Late Blight	1000	100
6.	Leaf Mold	1000	100
7.	Early Blight	1000	100
8.	Spider Mites Two-Spotted Spider Mite	1000	100
9.	Tomato Healthy	1000	100
10.	Septoria Leaf Spot	1000	100
Jumlah Gambar		10000	1000

4.2 Klasifikasi YOLO11 dan YOLOv8

Dalam penelitian ini, kita membandingkan dua model deteksi objek berbasis YOLO (You Only Look Once), yaitu YOLO11 dan YOLOv8, untuk mendeteksi penyakit pada daun tomat. Dua model ini digunakan dalam dua skenario yang berbeda untuk mengevaluasi kelebihan dan kekurangan masing-masing dalam hal akurasi, kecepatan deteksi, dan kemampuan generalisasi. Berikut adalah penjelasan dua skenario yang digunakan dalam penelitian ini.

4.2.1 YOLOv8

Model yang digunakan dalam penelitian ini adalah YOLOv8n-cls (YOLOv8 untuk klasifikasi), yang memiliki 1.447.690 parameter dan terdiri dari 30 lapisan. Semua gambar dalam dataset di-resize secara otomatis menjadi ukuran standar 224x224 piksel untuk memastikan konsistensi input dan efisiensi pemrosesan. Model ini digunakan untuk melatih dataset yang berisi 10.000 gambar penyakit daun tomat yang terbagi dalam 10 kelas penyakit, dengan 1.000 gambar untuk data validasi. Dalam hal optimasi, model menggunakan optimizer AdamW yang secara otomatis menyesuaikan learning rate dan momentum. Nilai learning rate yang digunakan adalah 0.000714, sementara momentum ditetapkan pada 0.9. Selain itu, model juga diatur dengan weight decay sebesar 0.0005 untuk mengurangi kemungkinan overfitting. Selama pelatihan, dilakukan warmup selama 3 epoch, yang bertujuan untuk memulai pelatihan dengan learning rate yang lebih rendah, sebelum akhirnya mencapai nilai optimal. Proses pelatihan ini dijalankan selama 20 epoch, di mana dropout

diatur pada 0.0, yang berarti tidak ada pengurangan unit jaringan selama pelatihan untuk mencegah overfitting. Seluruh proses pelatihan ini dilakukan dengan pengaturan default seperti multi-scale training dan mask overlap, yang memungkinkan model untuk lebih fleksibel dalam menangani variasi gambar. Tabel 4 adalah tabel hasil train dengan YOLOv8.


TABEL IV
HASIL TRAIN YOLOV8

epoch	time	train/loss	Accuracy_t op1	Accuracy_t op5	Val/loss
1	746.463	1.27057	0.886	0.997	0.37257
2	1283.43	0.38034	0.938	0.999	0.1997
3	1812.91	0.26928	0.955	1	0.15655
4	2417.77	0.22831	0.949	0.999	0.16152
5	3097.3	0.18009	0.964	1	0.10949
6	3624.78	0.1597	0.966	0.999	0.10426
7	4150.85	0.13141	0.967	1	0.10056
8	4783.34	0.11045	0.968	1	0.07132
9	5398.19	0.10032	0.972	1	0.07384
10	5923.58	0.09601	0.976	1	0.07093
11	6450.82	0.084	0.975	0.999	0.08533
12	6977.47	0.08385	0.975	1	0.06565
13	7509.63	0.07927	0.977	1	0.06185
14	8034.12	0.06699	0.977	1	0.0749
15	8565.59	0.06164	0.976	0.999	0.07428
16	9088.51	0.05934	0.983	1	0.05557
17	9611.07	0.05683	0.979	1	0.05796
18	10135.4	0.05117	0.983	0.999	0.0635
19	10657.9	0.04584	0.979	1	0.05665
20	11183.2	0.04531	0.985	1	0.05159

Setelah 20 epoch, model mencapai akurasi top-1 sebesar 98,5%, yang menunjukkan bahwa model dapat mengklasifikasikan gambar dengan benar dalam 98,5% kasus. Selain itu, akurasi top-5 mencapai 100%, yang berarti model memberikan prediksi yang benar dalam lima pilihan teratas pada 100% gambar.

Waktu yang dibutuhkan untuk memproses satu gambar adalah 8,6 ms (milidetik), yang menunjukkan efisiensi model dalam melakukan prediksi. Proses preprocessing (persiapan data sebelum dimasukkan ke model) memerlukan waktu hampir 0 ms, sedangkan proses loss dan postprocessing juga memakan waktu yang sangat sedikit, yang berarti model

berjalan dengan sangat cepat. Gambar 3 adalah grafik train model YOLOv8.



Gambar 3. Grafik Train Model YOLOv8

Gambar yang ditampilkan menunjukkan grafik pelatihan (training) dan evaluasi (validation) model selama 20 epoch. Grafik pertama menunjukkan train loss yang mengalami penurunan tajam dari nilai awal yang tinggi, yang mengindikasikan bahwa model belajar dengan cepat selama pelatihan. Penurunan loss yang tajam dari 1.27 pada epoch pertama hingga 0.045 pada epoch ke-20 mengindikasikan beberapa faktor kritis yang memvalidasi kualitas penelitian ini. Pertama, efektivitas transfer learning terlihat dari konvergensi yang cepat pada 5 epoch awal, dimana model pretrained YOLOv8n-cls yang telah dilatih pada ImageNet dapat dengan cepat beradaptasi untuk mengenali pola visual spesifik penyakit daun tomat. Kedua, kualitas dataset yang superior ditunjukkan oleh penurunan loss yang smooth tanpa fluktuasi berlebihan, mengindikasikan distribusi data yang seimbang dan karakteristik visual yang distinktif antar kelas penyakit.


Grafik val loss yang menunjukkan pola penurunan serupa dari 0.37 ke 0.052 dengan gap minimal terhadap train loss membuktikan kemampuan generalisasi yang excellent. Hal ini disebabkan oleh pengaturan regularisasi yang optimal dengan weight decay 0.0005 yang mencegah overfitting, stratified sampling yang memastikan representasi seimbang setiap kelas dalam data validasi, serta karakteristik visual penyakit daun tomat yang jelas seperti bercak, perubahan warna, dan tekstur daun yang mudah dibedakan oleh model.

Pola konvergensi ini menunjukkan bahwa transfer learning efektif untuk agricultural computer vision, mengonfirmasi kualitas dataset Kaggle Tomato Leaf Diseases Detection, membuktikan YOLOv8n-cls dengan 1.447.690 parameter optimal tanpa risiko underfitting atau overfitting, serta

menunjukkan potensi implementasi praktis yang tinggi karena model dapat dilatih dalam 20 epoch dengan akurasi tinggi.

Pada grafik ketiga, yaitu *metrics/accuracy_top1*, terlihat bahwa akurasi top-1 model meningkat pesat dari epoch ke epoch, mencapai sekitar 98% pada akhir pelatihan, yang menunjukkan bahwa model sangat akurat dalam memprediksi kelas yang benar pada gambar pertama. Sementara itu, pada grafik *metrics/accuracy_top5*, yang mengukur seberapa sering kelas yang benar muncul dalam lima prediksi teratas, akurasi model mencapai hampir 100%, menunjukkan bahwa model sangat efektif dalam mengidentifikasi kelas yang benar, meskipun prediksi pertama tidak tepat.

Secara keseluruhan, grafik ini menunjukkan bahwa model menunjukkan performa yang sangat baik dengan penurunan loss yang cepat dan peningkatan akurasi yang signifikan, baik pada prediksi top-1 maupun top-5, yang menandakan kemampuannya yang baik dalam mendeteksi penyakit pada daun tomat. Gambar 4 adalah *confusion matrix* train model YOLOv8.



Gambar 4. Confusion Matrix YOLOv8

Gambar yang ditampilkan adalah confusion matrix yang menunjukkan hasil prediksi model dalam mengklasifikasikan penyakit pada daun tomat. Matriks ini menggambarkan hubungan antara kelas yang benar (*true classes*) pada sumbu vertikal dan kelas yang diprediksi (*predicted classes*) pada sumbu horizontal.

Secara keseluruhan, model menunjukkan performa yang sangat baik, dengan sebagian besar nilai diagonal mendekati 100, yang menunjukkan bahwa model memprediksi dengan sangat akurat untuk sebagian besar kelas. Model berhasil mendeteksi berbagai jenis penyakit berdasarkan karakteristik visual yang spesifik pada setiap penyakit. Misalnya, untuk kelas Tomato Bacterial Spot yang ditandai dengan bercak-bercak kecil berwarna coklat kehitaman dengan tepi kuning yang tersebar di permukaan daun, Tomato Early Blight yang memiliki karakteristik bercak coklat konsentris berbentuk target dengan pola cincin yang jelas, dan Tomato Late Blight

yang menunjukkan bercak hijau kecoklatan dengan tepi putih keabu-abuan yang cepat menyebar, model memprediksi 100 gambar dengan benar tanpa kesalahan.

Proses deteksi yang dilakukan oleh model melibatkan analisis mendalam terhadap fitur-fitur visual yang menjadi ciri khas setiap penyakit. Model mengidentifikasi perubahan warna daun dari hijau normal menjadi variasi warna abnormal seperti kuning, coklat, atau kehitaman yang menjadi indikator awal adanya infeksi. Selain itu, model juga menganalisis pola bercak yang spesifik, seperti bentuk target pada Early Blight, pola mozaik pada Mosaic Virus, atau bercak bulat kecil dengan pusat abu-abu pada Septoria Leaf Spot. Tekstur permukaan daun yang mengalami perubahan, seperti nekrosis, klorosis, atau deformasi, juga menjadi parameter penting dalam proses klasifikasi. Model YOLO melakukan ekstraksi fitur melalui jaringan konvolusi yang mengidentifikasi edge, tekstur, dan pola kompleks, kemudian mengklasifikasikan gambar berdasarkan kombinasi fitur-fitur tersebut dalam satu proses inferensi yang cepat dan efisien. Hal ini menunjukkan bahwa model sangat efektif dalam mendeteksi penyakit-penyakit tersebut berdasarkan karakteristik visual yang dapat diamati secara objektif, menjadikannya solusi yang andal untuk diagnosis penyakit tanaman tomat secara real-time di lapangan.

Model juga menunjukkan kemampuan yang sangat baik dalam mengidentifikasi penyakit-penyakit lain dengan karakteristik yang berbeda. Tomato Yellow Leaf Curl Virus dikenali melalui gejala khas berupa daun yang menguning dan menggulung ke atas dengan pertumbuhan tanaman yang terhambat. Target Spot diidentifikasi melalui bercak bulat dengan pola cincin konsentris yang jelas berwarna coklat dengan pusat yang lebih terang. Leaf Mold ditandai dengan bercak kuning pada permukaan atas daun yang berkembang menjadi area nekrotik berwarna coklat. Spider Mites Two-Spotted Spider Mite dideteksi melalui bintik-bintik kecil kuning yang tersebar di seluruh permukaan daun, memberikan tampilan berbronze pada daun yang terinfeksi berat. Septoria Leaf Spot dikarakterisasi dengan bercak kecil bulat berwarna abu-abu dengan tepi gelap yang biasanya dimulai dari daun bagian bawah. Kemampuan model untuk membedakan karakteristik visual yang kompleks ini menunjukkan efektivitas arsitektur YOLO dalam melakukan klasifikasi multi-kelas dengan tingkat akurasi yang sangat tinggi, bahkan pada penyakit dengan gejala yang relatif mirip.

Secara keseluruhan, model menunjukkan performa yang sangat baik, dengan sebagian besar nilai diagonal mendekati 100, yang menunjukkan bahwa model memprediksi dengan sangat akurat untuk sebagian besar kelas. Misalnya, untuk kelas Tomato Bacterial spot, Tomato Early blight, dan Tomato Late blight, model memprediksi 100 gambar dengan benar, tanpa kesalahan. Hal ini menunjukkan bahwa model sangat efektif dalam mendeteksi penyakit-penyakit tersebut.

Namun, ada beberapa kesalahan prediksi kecil. Sebagai contoh, untuk Tomato Healthy, model salah memprediksi 4 gambar sebagai Tomato Bacterial spot, dan satu gambar sebagai Tomato Leaf Mold. Juga, beberapa kelas seperti Tomato Yellow Leaf Curl Virus dan Tomato Mosaic Virus

memiliki kesalahan prediksi, masing-masing dengan 1 gambar yang diprediksi secara salah.

Meskipun demikian, kesalahan ini relatif kecil dibandingkan dengan jumlah gambar yang benar-benar diprediksi dengan tepat, menunjukkan bahwa model secara keseluruhan sangat akurat dalam klasifikasi penyakit pada daun tomat. Confusion matrix ini memberi gambaran yang jelas tentang kinerja model dan area-area yang mungkin memerlukan sedikit perbaikan untuk meningkatkan akurasi lebih lanjut.

4.2.2 YOLO11

Proses pelatihan menggunakan model YOLOv8n-cls dilakukan selama 20 epoch untuk mendeteksi penyakit pada daun tomat. Dataset yang digunakan terdiri dari 10.000 gambar untuk pelatihan dan 1.000 gambar untuk validasi, dengan masing-masing gambar termasuk dalam 10 kelas penyakit daun tomat. Model dilatih menggunakan batch size 16 dan gambar berukuran 224x224 piksel. Parameter lainnya termasuk learning rate otomatis yang diatur oleh sistem, momentum 0.9, dan optimizer AdamW, yang disesuaikan secara otomatis dengan nilai $lr_0=0.000714$ dan $weight_decay=0.0005$. Tabel 5 adalah tabel hasil train dengan YOLO11.


TABEL V
HASIL TRAIN YOLO11

epoch	time	train/loss	Accuracy_t op1	Accuracy_t op5	Val/loss
1	556.011	0.98137	0.953	0.999	0.16172
2	1093.91	0.32161	0.949	1	0.1346
3	1629.59	0.26835	0.96	0.999	0.13111
4	2158.23	0.24348	0.974	1	0.07277
5	2686.98	0.19253	0.966	0.999	0.10147
6	3214.51	0.16936	0.966	0.999	0.10474
7	3746.95	0.14732	0.97	1	0.08792
8	4284.97	0.13013	0.974	1	0.07723
9	4817.98	0.115	0.969	1	0.07778
10	5356.16	0.09764	0.988	1	0.04542
11	5884.89	0.09007	0.988	1	0.05145
12	6415.74	0.08315	0.986	1	0.03731
13	6945.12	0.0689	0.986	1	0.03355
14	7478.86	0.06315	0.985	1	0.04696
15	8012.09	0.05504	0.989	0.999	0.04606
16	8551.66	0.05181	0.989	1	0.03576
17	9085.14	0.04594	0.994	1	0.02307
18	9616.08	0.03999	0.993	1	0.04403

19	1015 1.6	0.0366	0.991	1	0.02524
20	1068 6.8	0.03303	0.992	1	0.02954

Selama pelatihan, loss (kerugian) pada data pelatihan menunjukkan penurunan signifikan dari sekitar 0.981 pada epoch pertama hingga mencapai 0.033 pada epoch ke-20, menandakan bahwa model semakin baik dalam mempelajari pola data. Akurasi model meningkat pesat, dengan top-1 accuracy mencapai 95.3% pada epoch pertama dan mencapai 99.2% pada epoch terakhir. Di sisi lain, top-5 accuracy tetap sangat tinggi sepanjang pelatihan, mencapai 99.9% di sebagian besar epoch, yang menunjukkan bahwa model memberikan prediksi yang sangat akurat.

Kecepatan inferensi model juga sangat baik, dengan waktu inferensi per gambar hanya 9.6 ms, sementara preprocessing dan postprocessing hampir tidak mempengaruhi waktu, masing-masing mendekati 0 ms. Setelah pelatihan selesai, model diuji dengan data validasi, dan hasilnya menunjukkan top-1 accuracy sebesar 99.5% dan top-5 accuracy mencapai 100%, yang menunjukkan kemampuan model untuk mengklasifikasikan penyakit pada daun tomat dengan akurasi yang sangat tinggi. Gambar 5 adalah grafik train model YOLO11.



Gambar 5. Grafik Train YOLO11

Gambar yang ditampilkan menunjukkan grafik pelatihan dan evaluasi model selama 20 epoch. Grafik pertama di kiri atas menunjukkan train loss, yang menunjukkan penurunan signifikan dari sekitar 0.9 pada epoch pertama hingga mendekati 0.0 pada epoch terakhir. Penurunan yang tajam ini menunjukkan bahwa model belajar dengan cepat dari data pelatihan dan semakin baik dalam mengklasifikasikan penyakit pada daun tomat. Garis berwarna oranye (smooth) menggambarkan nilai loss yang lebih halus, memberikan


gambaran yang lebih stabil dari perubahan loss selama pelatihan.

Grafik kedua di kanan atas menunjukkan val loss, yang mengukur kinerja model pada data validasi. Seperti pada grafik pelatihan, val loss juga menunjukkan penurunan yang konsisten, mulai dari sekitar 0.15 pada epoch pertama dan turun hingga 0.025 pada epoch terakhir. Ini menunjukkan bahwa model tidak hanya belajar dengan baik dari data pelatihan, tetapi juga dapat menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya.

Grafik ketiga di kiri bawah menunjukkan top-1 accuracy, yang mengukur seberapa sering kelas yang benar diprediksi di posisi pertama oleh model. Akurasi ini terus meningkat sepanjang pelatihan, dari sekitar 95% pada epoch pertama hingga hampir 99% pada epoch ke-20. Grafik ini menunjukkan bahwa model semakin baik dalam mengklasifikasikan gambar dengan benar pada prediksi pertama.

Grafik terakhir di kanan bawah menunjukkan top-5 accuracy, yang mengukur seberapa sering kelas yang benar muncul dalam lima prediksi teratas. Akurasi ini hampir mencapai 100% di setiap epoch, yang menunjukkan bahwa model sangat andal dalam memberikan hasil yang benar meskipun tidak selalu di posisi pertama.

Secara keseluruhan, grafik-grafik ini menunjukkan bahwa model mengalami penurunan loss yang signifikan dan peningkatan akurasi yang stabil selama pelatihan, menunjukkan kinerja yang sangat baik dalam mendeteksi penyakit pada daun tomat dengan akurasi tinggi. Gambar 6 adalah *confusion matrix* train model YOLO11.



Gambar 6. Confusion Matrix YOLO11

Gambar yang ditampilkan adalah confusion matrix yang menggambarkan kinerja model dalam mengklasifikasikan penyakit pada daun tomat. Matriks ini menunjukkan hubungan antara kelas yang benar (true classes) yang ada pada sumbu vertikal dan kelas yang diprediksi (predicted classes) pada

sumbu horizontal. Nilai pada diagonal menunjukkan jumlah prediksi yang benar untuk setiap kelas penyakit, sedangkan nilai di luar diagonal menunjukkan kesalahan prediksi.

Secara keseluruhan, model menunjukkan kinerja yang sangat baik. Semua kelas seperti Tomato Bacterial spot, Tomato Early blight, dan Tomato Late blight diprediksi dengan 100 gambar benar, menunjukkan akurasi yang sempurna. Namun, ada beberapa kesalahan kecil pada beberapa kelas lainnya. Misalnya, pada Tomato Early blight, terdapat 2 gambar yang salah diprediksi sebagai Tomato Late blight. Selain itu, pada kelas Tomato Spider mites Two-spotted spider mite, terdapat 1 gambar yang salah diprediksi sebagai Tomato Late blight, dan pada Tomato Target Spot, terdapat 1 gambar yang salah diprediksi sebagai Tomato Leaf Mold.

Pada kelas Tomato Yellow Leaf Curl Virus, Tomato Mosaic Virus, dan Tomato Healthy, model memberikan prediksi yang sangat akurat, dengan 100 gambar benar untuk masing-masing kelas. Satu-satunya kesalahan besar terlihat pada background, yang salah diprediksi 1 gambar sebagai Tomato Target Spot, tetapi ini relatif kecil dibandingkan dengan total gambar yang benar.

Secara keseluruhan, confusion matrix ini menunjukkan bahwa model sangat efektif dalam mendeteksi penyakit pada daun tomat, dengan jumlah kesalahan prediksi yang sangat kecil. Prediksi yang benar mendominasi, menandakan bahwa model bekerja dengan akurat dan dapat diandalkan dalam aplikasi dunia nyata.

4.3 Pembahasan

Dari hasil pemaparan pada sub-bab 4.1 dan 4.2, dapat dilakukan studi perbandingan antara model YOLOv8 dan YOLO11 yang menunjukkan akurasi sangat tinggi dengan kecepatan inferensi real-time. model YOLOv8 (diajukan) mencapai akurasi sebesar 98.5%, menunjukkan kemampuan deteksi objek real-time yang sangat baik. Sementara itu, model YOLO11 (diajukan) menunjukkan hasil yang lebih baik dengan akurasi sebesar 99.4%, menjadikannya sebagai model dengan performa terbaik di antara semua yang diuji dalam penelitian ini. Model VGG-16 yang berbasis CNN memiliki akurasi sebesar 99%. Inception-V3, juga berbasis CNN dengan transfer learning, mencatatkan akurasi sebesar 93.8%, yang sedikit lebih rendah dibandingkan dengan model YOLO dan VGG-16. Terakhir, model ensemble yang menggabungkan VGG-16 dan NASNet Mobile mencapai akurasi sebesar 98.7%, yang menunjukkan performa yang sangat baik, meskipun masih sedikit lebih rendah daripada YOLO11.

Hal ini sesuai dengan teori bahwa YOLO, yang dirancang untuk deteksi objek real-time, cenderung lebih cepat dalam mengolah citra daripada model CNN yang lebih berat. Model CNN seperti VGG-16 dan Inception-V3 memang menunjukkan akurasi tinggi, tetapi memerlukan waktu pelatihan dan inferensi yang lebih lama. Sementara itu, model YOLOv8 dan YOLO11, meskipun lebih ringan, mampu mempertahankan akurasi yang sangat kompetitif dengan waktu deteksi yang lebih cepat.

Perbandingan antara model YOLO11 dan YOLOv8 ini menunjukkan bahwa YOLO11 lebih efisien dalam aplikasi lapangan yang membutuhkan deteksi cepat. Tabel 6

menunjukkan perbandingan nilai akurasi penelitian yang diajukan dengan penelitian terdahulu. Tabel 6 menjadi bukti empiris yang mendukung hipotesis penelitian bahwa model YOLO terbaru (khususnya YOLO11) dapat memberikan performa superior dalam deteksi penyakit daun tomat, baik dari segi akurasi maupun efisiensi komputasi.

TABEL VI
TABEL PERBANDINGAN AKURASI

No.	Peneliti	Model/Algoritma	Akurasi
1.	Diajikan	YOLOv8	98,5%
2.	Diajikan	YOLO11	99,4%
3.	Adias Pradana et al. [6]	CNN dengan arsitektur VGG-16	99%
4.	A. Nurdin et al. [7]	CNN dengan transfer learning Inception-V3	93,8%
5.	Pandiyaraju V et al.[8]	Ensemble VGG-16 dan NASNet Mobile	98,7%

V. KESIMPULAN

Kesimpulan dari hasil perbandingan akurasi yang ditampilkan adalah bahwa model YOLO11 (diajukan) memberikan performa terbaik dengan akurasi 99.4%, diikuti oleh model YOLOv8 (diajukan) yang menunjukkan akurasi 98.5%, yang keduanya unggul dalam deteksi objek real-time. Meskipun model berbasis CNN seperti VGG-16 dan Inception-V3 memiliki akurasi yang cukup tinggi (99% dan 93.8%), model YOLO lebih efisien dalam hal kecepatan deteksi, yang menjadikannya pilihan yang lebih baik untuk aplikasi deteksi penyakit tanaman secara real-time. Ensemble model VGG-16 dan NASNet Mobile, meskipun memiliki akurasi tinggi 98.7%, masih sedikit lebih rendah dibandingkan dengan YOLO11, tetapi tetap menunjukkan kinerja yang baik.

Secara keseluruhan, YOLO11 menawarkan kombinasi terbaik antara akurasi dan kecepatan deteksi, menjadikannya model yang paling unggul dalam penelitian ini. Namun, eksperimen lebih lanjut perlu dilakukan untuk mengoptimalkan hyperparameter pada model YOLOv8 dan YOLO11, seperti learning rate, batch size, dan epochs, guna meningkatkan akurasi tanpa mengorbankan kecepatan inferensi. Penelitian juga bisa fokus pada teknik augmentasi data yang lebih beragam, seperti cutout, mixup, atau cutmix, untuk meningkatkan kemampuan model dalam mengenali penyakit dalam berbagai kondisi.

REFERENSI

[1] D. L. Wibisana, J. D. Anggara, and Paiman, "RESPON PERTUMBUHAN DAN HASIL TANAMAN TOMAT (*Lycopersicum Esculentum*) DENGAN APLIKASI PGPR," *Jurnal Ilmiah Agrineca*, vol. 24, Jul. 2024.

[2] D. R. Sihotang, D. Syafitri, D. C. Octaviana, P. A. Septianingrum, and A. Asy-Syfaityyah, "Identification of Pests and Diseases in Tomato Plants in Jeprono Village, Karangbangun District, Karanganyar Regency," *Jurnal Biologi Tropis*, vol. 25, no. 1, pp. 381–393, Feb. 2025, doi: 10.29303/jbt.v25i1.8229.

[3] H. M. Zayani et al., "Deep Learning for Tomato Disease Detection with YOLOv8," *Engineering, Technology and Applied Science Research*, vol. 14, no. 2, pp. 13584–13591, Apr. 2024, doi: 10.48084/etasr.7064.

[4] R. Sapkota, Z. Meng, M. Churuvija, X. Du, Z. Ma, and M. Karkee, "Comprehensive Performance Evaluation of YOLOv12, YOLO11, YOLOv10, YOLOv9 and YOLOv8 on Detecting and Counting Fruitlet in Complex Orchard Environments," *ResearchGate*, Jul. 2024, [Online]. Available: <http://arxiv.org/abs/2407.12040>

[5] R. Khanam and M. Hussain, "YOLOv11: An Overview of the Key Architectural Enhancements," *ArXiv*, Oct. 2024, [Online]. Available: <http://arxiv.org/abs/2410.17725>

[6] M. Adias Pradana et al., "Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN) VGG16," *Jurnal Riset Inovasi Bidang Informatika dan Pendidikan Informatika*, vol. 4, no. 2, 2023, doi: 10.31284/j.kernel.2023.v4i2.6829.

[7] A. Nurdin, D. Satria, Y. Kartika, A. Rezha, and E. Najaf, "Klasifikasi Penyakit Daun Tomat Dengan Metode Convolutional Neural Network Menggunakan Arsitektur Inception-V3," 2024.

[8] P. V et al., "Improved tomato leaf disease classification through adaptive ensemble models with exponential moving average fusion and enhanced weighted gradient optimization," *Front Plant Sci*, vol. 15, 2024, doi: 10.3389/fpls.2024.1382416.

[9] M. Nina Adlini, A. Hanifa Dinda, S. Yulinda, O. Chotimah, and S. Julia Merliyana, "METODE PENELITIAN KUALITATIF STUDI PUSTAKA," *Edumaspul - Jurnal Pendidikan*, vol. 6, no. 1, pp. 974–980, Mar. 2022.

[10] kaustubh b, "Tomato leaf disease detection," Kaggle. Accessed: Jan. 03, 2025. [Online]. Available: <https://www.kaggle.com/datasets/kaustubhb999/tomatoleaf>

[11] L. He, Y. Zhou, L. Liu, and J. Ma, "Research and Application of YOLOv11-Based Object Segmentation in Intelligent Recognition at Construction Sites," *Buildings*, vol. 14, no. 12, Dec. 2024, doi: 10.3390/buildings14123777.

[12] M. Talib, A. H. Y. Al-Noori, and J. Suad, "YOLOv8-CAB: Improved YOLOv8 for Real-time Object Detection," *Karbala International Journal of Modern Science*, vol. 10, no. 1, pp. 56–68, 2024, doi: 10.33640/2405-609X.3339.

[13] R. Oktafiani, A. Hermawan, and D. Avianto, "Pengaruh Komposisi Split data Terhadap Performa Klasifikasi Penyakit Kanker Payudara Menggunakan Algoritma Machine Learning," *Jurnal Sains dan Informatika*, pp. 19–28, Jun. 2023, doi: 10.34128/jsi.v9i1.622.

[14] A. Nurhopipah and U. Hasanah, "Dataset Splitting Techniques Comparison For Face Classification on CCTV Images," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 14, no. 4, p. 341, Oct. 2020, doi: 10.22146/ijccs.58092.

[15] V. R. Joseph and A. Vakayil, "SPlit: An Optimal Method for Data Splitting," *Technometrics*, vol. 64, no. 2, pp. 166–176, 2022, doi: 10.1080/00401706.2021.1921037.

[16] T. Erlina and M. Fikri, "YOLO ALGORITHM-BASED VISITOR DETECTION SYSTEM FOR SMALL RETAIL STORES USING SINGLE BOARD COMPUTER," May 2023.

[17] M. Sohan, T. Ram, and V. Ch, "A Review on YOLOv8 and Its Advancements," 2024, pp. 529–545. doi: 10.1007/978-981-99-7962-2_39.

[18] J. E. Gallagher and E. J. Oughton, "Surveying You Only Look Once (YOLO) Multispectral Object Detection Advancements, Applications, and Challenges," *IEEE Access*, vol. 13, pp. 7366–7395, 2025, doi: 10.1109/ACCESS.2025.3526458.

[19] G. Rasyid and J. Sutopo, "Comparison of YOLO-v8 and YOLO-v10 in Detecting Human Facial Emotions," *Indonesian Journal of Applied Technology*, vol. 2, no. 1, Dec. 2024, doi: 10.47134/ijat.v2i1.3395.

[20] I. Topan Adib Amrulloh et al., "EVALUASI AUGMENTASI DATA PADA DETEKSI PENYAKIT DAUN TEBU DENGAN YOLOV8," 2024.

[21] X. Wang, Z. Zhang, and X. Shang, "Research on Improved YOLO11 for Detecting Small Targets in Sonar Images Based on Data Enhancement," *Applied Sciences (Switzerland)*, vol. 15, no. 12, Jun. 2025, doi: 10.3390/app15126919.