



Model Prediktif Penyakit Tanaman Tomat Menggunakan Arsitektur EfficientNetB0 *Tomato Disease Prediction Model Using EfficientNetB0 Architecture*

Tri Ferga Prasetyo¹, Sunardi², Abdul Fadlil³

¹Program Studi Doktor Informatika, Universitas Ahmad Dahlan, Yogyakarta, Indonesia

¹Program Studi Informatika, Universitas Majalengka, Majalengka, Indonesia

^{2,3}Program Studi Teknik Elektro, Universitas Ahmad Dahlan, Yogyakarta, Indonesia

¹2537083010@webmail.uad.ac.id, ²sunardi@mti.uad.ac.id, ³fadlil@mti.uad.ac.id

Abstract

Tomato (Solanum lycopersicum) is highly vulnerable to a range of foliar diseases that can reduce yield and hinder crop quality, particularly when early symptoms are difficult to distinguish in field conditions. To address this challenge, this study develops a predictive model for automatic tomato leaf disease classification using a lightweight EfficientNetB0 architecture. The dataset consists of 5,967 images from nine categories, combining 70% publicly available Kaggle PlantVillage data and 30% real-field images captured under natural outdoor illumination. The methodological pipeline includes preprocessing, data augmentation, and transfer learning, followed by fine-tuning of the upper layers of EfficientNetB0 to improve its ability to generalize toward field-specific variations such as uneven lighting and complex backgrounds. Evaluation results show that the model achieves an accuracy of 89%, with macro-average and weighted-average scores of 90%. These findings demonstrate that EfficientNetB0 provides an effective balance between predictive accuracy and computational efficiency, supporting its potential deployment in early detection systems and edge-based agricultural applications for real-time tomato disease monitoring.

Keywords: CNN, Deep Learning, EfficientNetB0, Plant Disease Detection, Tomato

Abstrak

Tomat (*Solanum lycopersicum*) sangat rentan terhadap berbagai penyakit daun yang dapat menurunkan hasil panen dan memengaruhi kualitas tanaman, terutama ketika gejala awal sulit dibedakan secara visual di kondisi lapangan. Untuk mengatasi permasalahan tersebut, penelitian ini mengembangkan model prediksi untuk klasifikasi otomatis penyakit daun tomat menggunakan arsitektur ringan EfficientNetB0. Dataset yang digunakan terdiri dari 5.967 citra dalam sembilan kategori, yang merupakan kombinasi dari 70% data publik PlantVillage (Kaggle) dan 30% citra lapangan nyata yang diambil dengan pencahayaan alami di luar ruangan. Tahapan metodologi meliputi prapemrosesan, augmentasi data, dan transfer learning, kemudian dilanjutkan dengan fine-tuning pada lapisan atas EfficientNetB0 untuk meningkatkan kemampuan generalisasi terhadap variasi khas lapangan seperti pencahayaan tidak merata dan latar belakang kompleks. Hasil evaluasi menunjukkan bahwa model mencapai akurasi sebesar 89%, dengan nilai macro-average dan weighted-average sebesar 90%. Temuan ini menunjukkan bahwa EfficientNetB0 mampu memberikan keseimbangan yang efektif antara akurasi prediksi dan efisiensi komputasi, sehingga mendukung potensinya untuk diterapkan pada sistem deteksi dini serta aplikasi pertanian berbasis edge device untuk pemantauan penyakit tomat secara *real-time*.

Kata kunci: CNN, Deep Learning, Deteksi Penyakit Tanaman, EfficientNetB0, Tomat


1. Pendahuluan

Pertanian merupakan sektor strategis yang berperan penting dalam pemenuhan kebutuhan pangan serta menopang perekonomian di berbagai negara, termasuk Indonesia [1], [2]. Salah satu komoditas hortikultura yang memiliki nilai ekonomi tinggi dan peran penting dalam ketahanan pangan adalah tomat (*Solanum lycopersicum*). Tomat banyak dimanfaatkan sebagai bahan pangan maupun bahan baku industri dengan tingkat permintaan yang relatif stabil. Namun demikian, produktivitas dan kualitas tomat sangat rentan terhadap

gangguan penyakit tanaman, khususnya penyakit daun, yang dapat menyebabkan penurunan hasil panen secara signifikan apabila tidak terdeteksi sejak dini.

Produksi tomat global menunjukkan tren peningkatan dari tahun ke tahun, dengan Indonesia berkontribusi sekitar 1,14 juta ton dan menunjukkan kecenderungan pertumbuhan positif dalam beberapa dekade terakhir, [3]. Dalam konteks ilmu pertanian modern (crop science), produktivitas tanaman ditentukan oleh keterpaduan antara pemuliaan tanaman, fisiologi tanaman, dan ekologi tanaman, termasuk interaksi

tanaman dengan hama dan penyakit [4]. Penyakit daun tomat seperti *Early Blight*, *Late Blight*, *Septoria Leaf Spot*, serta penyakit akibat bakteri dan virus merupakan faktor pembatas utama dalam sistem budidaya tomat, terutama pada wilayah beriklim tropis yang memiliki kelembapan tinggi [5], [6].



Gambar 1. Peta Produksi Tomat Dunia Tahun 2023 [7]

Indonesia bergantung pada sektor agrikultur sebagai sumber penghasilan utama yang mendukung ekonomi negara [8]. Sebagian besar warga Indonesia bekerja sebagai petani. Perkembangan teknologi memberikan manfaat perubahan yang dibawa oleh revolusi industri 4.0. Teknologi ini membawa dampak signifikan di berbagai sektor industri di Indonesia, termasuk di bidang pertanian. Kementerian Pertanian sangat mendukung transformasi pertanian menuju industri 4.0 [9].

Berdasarkan hasil Sensus Pertanian 2023 yang dirilis oleh Badan Pusat Statistik (BPS), jumlah usaha pertanian perorangan di Indonesia tercatat sekitar 29,34 juta unit, menurun dari 31,7 juta unit pada tahun 2013 (BPS, 2023). Penurunan ini menunjukkan urgensi regenerasi petani muda yang melek teknologi untuk menjaga keberlanjutan sektor pertanian. [10].

Salah satu tanaman yang menarik perhatian adalah varietas tanaman hortikultura. Hortikultura merupakan salah satu cabang ilmu dalam bidang pertanian yang mencakup semua aktivitas pengelolaan tanaman buah, sayur, tanaman obat, dan tanaman hias. Hortikultura berperan sebagai sumber makanan, komponen kesehatan, dan elemen keindahan [11]. Hortikultura memiliki kontribusi yang signifikan dalam pemenuhan kebutuhan nutrisi masyarakat, memberikan bahan mentah untuk industri farmasi dan kosmetik, serta menghias lingkungan [12], [13].

Produk hortikultura memiliki nilai ekonomi tinggi dan umumnya memerlukan metode budidaya yang lebih intensif [14], termasuk penerapan teknologi canggih seperti sistem irigasi otomatis, jaringan *Internet of Things* (IoT), dan kecerdasan buatan atau *Artificial Intelligent* (AI) untuk meningkatkan hasil pertanian

serta kualitas produk [2]. Salah satu perhatian utama dalam kajian hortikultura zaman sekarang adalah penciptaan sistem cerdas untuk budidaya tomat, yang memanfaatkan kombinasi IoT dan AI untuk meningkatkan pertumbuhan tanaman [15], mendeteksi berbagai penyakit, serta mengatur lingkungan tanam secara langsung [12].

Dalam upaya mempertahankan produktivitas hortikultura yang semakin menantang akibat perubahan iklim, tekanan hama-penyakit [16], dan intensifikasi budidaya, tomat (*Solanum lycopersicum*) tetap menempati posisi strategis sebagai komoditas pangan dan ekonomi yang rentan terhadap kerugian hasil besar ketika serangan penyakit daun seperti *Early Blight* (*Alternaria spp.*), *Late Blight* (*Phytophthora spp.*), *Septoria Leaf Spot*, dan bercak bakteri terjadi secara endemik atau epidemik [17]. Keadaan ini menuntut sistem deteksi dini yang cepat, akurat, dan dapat dioperasikan di lapangan agar intervensi agronomis dapat dilaksanakan secara tepat waktu dan ekonomis [4]. Beberapa penelitian awal menunjukkan bahwa teknik visi komputer dan deep learning mampu mencapai akurasi deteksi yang tinggi pada dataset terkontrol [18], Salah satu studi penting menggunakan dataset PlantVillage (5.967 citra) dan berhasil membuktikan bahwa metode ini layak digunakan untuk klasifikasi penyakit tanaman.

Namun, penelitian tersebut juga menyoroti adanya penurunan kinerja ketika model diterapkan pada kondisi lapangan yang lebih kompleks (domain shift). Variasi pencahayaan, latar belakang, jenis varietas tanaman, serta perbedaan perangkat kamera dapat memengaruhi hasil prediksi. Karena itu, pengembangan model tidak hanya harus fokus pada akurasi [19] tetapi juga pada efisiensi komputasi. Aspek ini penting agar model dapat dijalankan pada perangkat edge seperti smartphone atau Raspberry Pi tanpa mengurangi keandalan prediksi. [20].

Kemajuan deep learning, khususnya Convolutional Neural Network (CNN), telah mempercepat pengembangan sistem deteksi penyakit tanaman berbasis citra. Berbagai arsitektur seperti ResNet, InceptionV3, dan YOLOv8 telah diterapkan dengan tingkat kinerja yang beragam [21], [22]. Meskipun demikian, banyak model masih menghadapi keterbatasan dalam efisiensi komputasi dan ukuran parameter ketika diimplementasikan pada perangkat lapangan [23].

Dalam aspek desain arsitektur, keluarga EfficientNet menawarkan terobosan melalui mekanisme compound scaling, yakni pengaturan simultan terhadap kedalaman, lebar, dan resolusi model. Pendekatan ini memungkinkan keseimbangan yang lebih baik antara akurasi dan biaya komputasi [15], Varian EfficientNet-B0 hingga B7 terbukti memiliki performa transfer learning yang kuat pada berbagai tugas visi komputer,

sehingga menjadi fondasi yang menarik untuk aplikasi pertanian presisi [16].

Varian yang lebih ringan seperti EfficientNet-B0 sering dipilih karena jejak memori yang kecil dan latensi inferensi yang rendah [24]. Karakteristik ini menjadikannya relevan untuk sistem deteksi dini penyakit tanaman tomat yang perlu berjalan pada perangkat dengan sumber daya terbatas, seperti smartphone atau modul edge computing[25].

EfficientNetB0 menjadi salah satu arsitektur CNN modern yang menawarkan efisiensi tinggi dengan akurasi kompetitif melalui pendekatan *compound scaling* [26], [27]. Dengan kapasitas ringan dan kemampuan generalisasi yang baik, model ini potensial digunakan sebagai dasar sistem pendeteksi penyakit tomat berbasis citra daun yang siap diterapkan pada skala operasional [28].

Tujuan penelitian ini adalah mengimplementasikan dan mengevaluasi performa model prediktif penyakit tomat menggunakan arsitektur EfficientNetB0, dengan fokus pada akurasi dan efisiensi komputasi tanpa integrasi data lingkungan atau sensor tambahan [29].

Sejumlah penelitian terdahulu telah mengkaji penerapan deep learning untuk klasifikasi penyakit daun tomat berbasis citra. Saeed et al. [18] menerapkan pendekatan transfer learning berbasis Convolutional Neural Network (CNN) untuk mendeteksi penyakit daun tomat dan melaporkan akurasi tinggi pada dataset PlantVillage. Namun, penelitian tersebut dilakukan pada lingkungan data yang relatif terkontrol sehingga belum sepenuhnya merepresentasikan kondisi lapangan yang kompleks.

Sun et al. [19] mengusulkan pendekatan deep learning berbasis fusi fitur global dan lokal untuk mendeteksi penyakit daun tomat dengan performa yang baik, namun arsitektur yang digunakan memiliki kompleksitas komputasi yang relatif tinggi sehingga kurang optimal untuk implementasi pada perangkat edge.

Penelitian lain oleh Desai et al. [20] memanfaatkan CNN untuk deteksi penyakit daun secara real-time pada Raspberry Pi, tetapi menghadapi keterbatasan akurasi ketika diaplikasikan pada variasi pencahayaan dan latar belakang alami.

Beberapa studi juga mengevaluasi berbagai arsitektur CNN modern seperti ResNet, Inception, dan MobileNet untuk klasifikasi penyakit tanaman [21], [22]. Meskipun model-model tersebut menunjukkan performa yang kompetitif, sebagian besar masih memiliki ukuran parameter yang besar atau latensi inferensi yang tinggi, sehingga kurang efisien untuk aplikasi pertanian presisi berbasis perangkat dengan sumber daya terbatas.

Berdasarkan tinjauan tersebut, masih diperlukan pengembangan model klasifikasi penyakit daun tomat yang tidak hanya akurat, tetapi juga ringan dan efisien secara komputasi. Oleh karena itu, penelitian ini memfokuskan penggunaan arsitektur EfficientNetB0 yang memiliki keseimbangan optimal antara akurasi dan efisiensi melalui mekanisme *compound scaling*, serta diuji menggunakan kombinasi dataset publik dan citra lapangan nyata untuk meningkatkan kemampuan generalisasi model terhadap kondisi operasional di lapangan.


2. Metode Penelitian

Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit tanaman tomat berbasis citra daun menggunakan arsitektur EfficientNetB0. Kerangka umum penelitian ditunjukkan pada Gambar 2. Metode Penelitian mulai dari perencanaan, pengumpulan data, pra-pemrosesan data, pembagian data, pelatihan model, hingga tahap evaluasi dan pengujian.

Tahapan pertama yaitu perencanaan, dimulai dengan perumusan masalah yang menyoroti kesulitan petani dalam mendeteksi penyakit daun tomat secara dini melalui pengamatan visual. Setelah itu dilakukan studi literatur terhadap penelitian terdahulu untuk meninjau efektivitas model CNN dalam pengenalan pola penyakit tanaman dan mengevaluasi keunggulan arsitektur modern seperti ResNet, MobileNet, serta EfficientNet dari sisi efisiensi parameter dan ketepatan klasifikasi.

Data yang digunakan dalam penelitian ini berasal dari dua sumber utama, yaitu dataset publik (PlantVillage) dan data lapangan hasil pengambilan citra secara langsung di area pertanian tomat di daerah pangalengan bandung dan garut. Pengumpulan data lapangan bertujuan untuk memperkaya variasi kondisi pencahayaan, latar belakang, dan orientasi daun, sehingga model yang dibangun memiliki kemampuan generalisasi lebih baik terhadap kondisi nyata. Secara keseluruhan, dataset terdiri atas sembilan kelas penyakit, yakni *Early Blight*, *Blossom End Rot*, *Rotten Tomato*, *Tomato Anthracnose*, *Septoria Leaf Spot*, *Bacterial Spot*, *Tomato Yellow Leaf Curl Virus*, *Spotted Wilt Virus*, dan *Late Blight*.

Seluruh citra yang diperoleh melalui kedua sumber tersebut diproses terlebih dahulu agar memenuhi standar input arsitektur EfficientNetB0. Setiap citra dikonversi ke format RGB dan diubah ukurannya menjadi 224×224 piksel. Nilai piksel kemudian dinormalisasi ke rentang [0,1] untuk mempercepat proses konvergensi selama pelatihan.



Gambar 2 Metode Penelitian

Normalisasi Min–Max bertujuan untuk mengubah nilai asli X kedalam rentang 0–1 agar seluruh data berada pada skala yang sama. Prosesnya dilakukan dengan mengurangi nilai X dengan nilai minimum fitur ($X_{\min}$), lalu hasilnya dibagi dengan selisih antara nilai maksimum dan minimum ($X_{\max} - X_{\min}$). Nilai X' adalah nilai yang telah dinormalisasi, X adalah nilai awal, $X_{\min}$ adalah nilai terkecil pada fitur tersebut, sementara $X_{\max}$ adalah nilai terbesarnya. Dengan cara ini, nilai terendah akan menjadi 0 dan nilai tertinggi menjadi 1, sehingga model dapat belajar secara lebih stabil dan konsisten [30]. Persamaan (1) menunjukkan cara kerja normalisasi Min–Max, yaitu proses mengubah nilai asli suatu fitur X menjadi nilai baru X' dalam rentang 0 sampai 1

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

Untuk meningkatkan keragaman *dataset* tanpa menambah jumlah data secara signifikan maka diterapkan proses augmentasi berupa rotasi acak, *flipping* horizontal, dan zoom acak sebesar $\pm 20\%$. Augmentasi ini membantu model agar lebih tangguh terhadap variasi bentuk, posisi, dan orientasi daun tomat.

$$I'(x, y) = I(x * \cos\theta - y * \sin\theta, x * \sin\theta + y * \cos\theta) \quad (2)$$

Persamaan (2) digunakan untuk melakukan transformasi rotasi pada citra, dimana $I'(x, y)$ adalah

nilai intensitas baru pada koordinat (x, y) setelah citra diputar sebesar sudut θ . Variabel x dan y merupakan posisi koordinat piksel sebelum rotasi, sedangkan fungsi $I(x\cos\theta - y\sin\theta, x\sin\theta + y\cos\theta)$ menunjukkan posisi piksel asal yang digunakan untuk menghasilkan nilai intensitas pada posisi yang baru. Operasinya bekerja dengan menghitung koordinat lama berdasarkan sudut rotasi, lalu mengambil nilai intensitas piksel dari posisi tersebut (interpolasi *bilinear* biasanya digunakan agar hasil lebih halus). Dengan cara ini, citra dapat diputar tanpa mengubah struktur nilai intensitas aslinya, hanya memindahkan posisinya dalam ruang koordinat.

Arsitektur EfficientNetB0 digunakan sebagai tulang punggung (*backbone*) model untuk mengekstraksi fitur penting dari citra daun. Arsitektur ini dipilih karena memiliki keseimbangan optimal antara akurasi dan efisiensi komputasi melalui mekanisme *compound scaling* yang menyesuaikan kedalaman, lebar, dan resolusi jaringan secara proporsional.

Lapisan *backbone* dibekukan dengan menerapkan strategi *transfer learning* sehingga bobot pra-latih dari ImageNet dapat dimanfaatkan sebagai ekstraktor fitur utama. Di atas lapisan tersebut ditambahkan blok klasifikasi sederhana yang terdiri atas GlobalAveragePooling2D, Dropout layer dengan laju 0,3 untuk mengurangi risiko *overfitting*, dan Dense layer beraktivasi softmax dengan jumlah neuron sesuai sembilan kelas penyakit tomat. Lapisan klasifikasi ini memiliki total parameter terlatih sebanyak 11.529, menjadikan model efisien untuk implementasi di perangkat dengan sumber daya terbatas.

Proses pelatihan dilakukan menggunakan *optimizer* Adam dengan *learning rate* sebesar 0,001 dan fungsi kerugian (*loss function*) *categorical cross-entropy*. Kerangka penelitian yang ditunjukkan pada gambar 2 metode penelitian menggambarkan alur sistematis mulai dari perencanaan hingga tahap pelaporan. Proses dimulai dengan perumusan masalah dan studi literatur sebagai dasar penetapan arah penelitian. Selanjutnya dilakukan pengumpulan data citra dari *dataset* publik maupun data tambahan dari pengambilan gambar secara langsung. Data tersebut kemudian melalui tahap pra-pemrosesan untuk menormalkan kualitas citra, diikuti augmentasi guna meningkatkan keragaman data dan mengurangi risiko *overfitting*.

Dataset dibagi kedalam *subset* pelatihan, validasi, dan pengujian untuk memastikan evaluasi model yang objektif. Model klasifikasi kemudian dibangun dan dilatih menggunakan data pelatihan, sementara performanya dipantau melalui data validasi. Setelah model mencapai performa optimal, dilakukan evaluasi akhir menggunakan data uji. Tahap terakhir adalah pengujian dengan data luar untuk menilai kemampuan generalisasi model pada kondisi nyata sebelum penelitian dinyatakan selesai.

3. Hasil dan Pembahasan

Penelitian ini menghasilkan model klasifikasi penyakit tanaman tomat berbasis citra daun dengan arsitektur EfficientNetB0. Model dirancang untuk mengenali sembilan kelas penyakit utama dengan efisiensi parameter tinggi dan akurasi yang stabil. EfficientNetB0 dipilih karena mampu menyeimbangkan akurasi dan kecepatan inferensi melalui mekanisme compound scaling, menjadikannya ideal untuk sistem *edge computing* dan aplikasi pertanian cerdas.

3.1. Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini merupakan gabungan dari beberapa sumber untuk memastikan keragaman visual dan tingkat generalisasi yang baik pada model. Sumber pertama berasal dari PlantVillage yang diunduh melalui Kaggle dengan ribuan citra daun tomat yang telah dikategorikan menurut jenis penyakit. *Dataset* ini dipilih karena memiliki anotasi yang jelas, kualitas citra tinggi, dan telah menjadi referensi standar dalam penelitian klasifikasi penyakit tanaman berbasis *deep learning*.

Selain itu, *dataset* tambahan diambil dari repositori Mendeley Data untuk memperkaya variasi pola penyakit yang mungkin tidak sepenuhnya terwakili pada PlantVillage, terutama untuk kategori seperti *Tomato Anthracnose* dan *Blossom End Rot*. *Dataset* publik tersebut kemudian dilengkapi dengan *dataset* dari hasil pengambilan foto lapangan yang dilakukan secara langsung menggunakan kamera Samsung Galaxy pada kondisi siang hari dengan pencahayaan alami.



Gambar 3. Penyakit Bacterial Spot

Bacterial Spot merupakan infeksi yang menyerang tanaman seperti tomat, cabai, dan berbagai spesies dalam keluarga *Solanaceae* yang disebabkan oleh bakteri *Xanthomonas*, dengan fokus utama pada *Xanthomonas campestris* pv. *Vesicatoria* seperti terlihat pada Gambar 3. Keluhan ini memunculkan bercak kecil berwarna coklat gelap pada daun dan buah, dengan setiap bercak dikelilingi oleh halo yang berwarna kuning. Penyakit ini berkembang dengan cepat di

lingkungan yang hangat dan lembab, terkhusus saat terdapat cipratan air dari hujan ataupun irigasi. *Bacterial Spot* dapat mengakibatkan penurunan signifikan pada kualitas dan kuantitas hasil panen buah.



Gambar 4. Penyakit Early Blight

Penyakit Early Blight seperti terlihat pada Gambar 4 merupakan infeksi jamur yang menyerang tanaman tomat, yang disebabkan oleh *Alternaria solani*. Ciri-ciri dari penyakit ini adalah munculnya bintik-bintik coklat tua yang terlihat seperti cincin konsentris pada bagian daun, batang, atau buah. Penyakit ini biasanya menyerang tanaman yang sudah berumur dan menyebabkan daun menjadi kuning sebelum akhirnya jatuh.

Late blight merupakan penyakit tanaman tomat yang disebabkan oleh patogen yang mirip dengan jamur *Phytophthora infestans* dan sangat merusak, dapat dilihat pada Gambar 5. Gejalanya termasuk bercak air yang cepat berubah menjadi coklat kehitaman, yang sering disertai dengan jamur putih di bawah daun. Penyakit ini dapat dengan cepat membuat daun, batang, dan buah rusak sepenuhnya.



Gambar 5. Merupakan penyakit Late Blight

Penyakit Septoria Leaf seperti pada Gambar 6 terjadi akibat infeksi jamur *Septoria lycopersici*. Tandanya terlihat sebagai bercak kecil berwarna abu-abu yang dikelilingi pinggiran coklat tua, sering kali muncul dalam jumlah yang banyak dan menyebar dengan cepat. Kondisi ini sering kali terlihat pada cuaca

yang lembap dan dapat menyebabkan hilangnya daun secara signifikan.



Gambar 6. Penyakit Septoria Leaf



Gambar 7. Penyakit Yellow curl virus

Gambar 7 merupakan penyakit yang disebabkan oleh virus gulung daun tomat (tomato yellow leaf curl virus), yang ditularkan oleh kutu kebul (*Bemisia tabaci*). Daun menjadi menguning, menggulung ke atas, mengecil, dan kerdil. Penyakit ini sangat merugikan karena menghasilkan hasil yang tidak dapat diterima.

Proses pengambilan citra lapangan dilakukan di beberapa kebun tomat di wilayah dataran rendah dan sedang, dengan latar belakang alami dan variasi posisi daun. Pendekatan ini bertujuan untuk meningkatkan kehandalan model terhadap kondisi nyata yang lebih kompleks dibanding citra laboratorium. *Dataset* gabungan ini terdiri dari sembilan kelas, yaitu *Early Blight*, *Blossom End Rot*, *Rotten Tomato*, *Tomato Anthracnose*, *Septoria Leaf Spot*, *Bacterial Spot*, *Tomato Yellow Leaf Curl Virus*, *Spotted Wilt Virus*, dan *Late Blight*.

Dengan penggabungan tiga sumber ini, total data yang digunakan untuk pelatihan dan pengujian mencapai 5.967 citra dengan distribusi seimbang per kelas. Setiap citra kemudian diverifikasi secara visual untuk memastikan tidak ada duplikasi, citra buram, atau citra non-daun yang dapat menurunkan akurasi model.



Gambar 8. Penyakit Blossom End Rot

Blossom end rot pada Gambar 8 bukanlah infeksi penyakit, melainkan permasalahan fisik yang disebabkan oleh kurangnya kalsium pada tomat. Gejalanya terlihat sebagai busuk hitam atau kehitaman di bagian bawah buah (di lokasi bunga). Hal ini sering disebabkan oleh ketidakstabilan dalam penyiraman atau rendahnya kadar kalsium (Ca) di dalam tanah.



Gambar 9. Merupakan penyakit buah Rotten Tomato

Rotten tomato seperti terlihat pada Gambar 9 merupakan istilah umum yang digunakan untuk menggambarkan buah tomat yang mengalami kerusakan parah akibat infeksi mikroorganisme atau kondisi penyimpanan yang buruk. Kerusakan ini dapat muncul dalam bentuk buah yang melunak, berair, berjamur, menghitam, atau mengalami pelunakan jaringan. Beberapa patogen yang sering menyebabkan pembusukan pada tomat antara lain jamur *Rhizopus stolonifer*, *Alternaria alternata*, dan berbagai bakteri pelunak jaringan (*soft rot bacteria*) seperti *Pectobacterium* atau *Erwinia*. Istilah ini tidak merujuk pada satu jenis penyakit tertentu, melainkan mencakup berbagai bentuk pembusukan yang disebabkan oleh faktor biologis maupun lingkungan.

Tomato Spotted Wilt Virus (TSWV) pada Gambar 10 merupakan penyakit penting pada tanaman tomat yang ditularkan oleh thrips, serangga kecil pengisap cairan tanaman. Infeksi virus ini menimbulkan sejumlah gejala khas, seperti daun yang menguning kecoklatan, keriput, serta menunjukkan gejala layu, terutama pada daun muda. Pada bagian buah, penyakit ini menghasilkan pola bercak melingkar (*ring spot*) atau bercak berwarna

ungu-kecoklatan yang menjadi ciri utama serangan TSWV. Penyakit ini dapat menyebar dengan cepat di lapangan karena thrips membawa dan memindahkan virus dari satu tanaman ke tanaman lainnya.



Gambar 10. Penyakit *Spotted Wild Virus*



Gambar 11. Penyakit *Tomato Anthracnose*

Jamur *Colletotrichum* seperti terlihat pada Gambar 11 menyebabkan *anthracnose*, yaitu buah yang telah matang menunjukkan tanda-tanda seperti lekuk kecil cekung berwarna coklat yang terus melebar. Buah menjadi lembek dan kualitasnya menurun.

3.2. Pra pemrosesan data

Tahap pra-pemrosesan dilakukan untuk memastikan seluruh citra memiliki ukuran, format, dan kualitas yang seragam sebelum dimasukkan kedalam model *deep learning*. Proses ini diawali dengan penghapusan area yang tidak relevan pada setiap citra untuk menonjolkan bagian daun tomat yang menjadi objek utama. Langkah ini membantu model berfokus pada fitur penting seperti warna, bentuk, dan tekstur daun tanpa gangguan dari latar belakang.

Setelah itu, seluruh citra distandarisasi ukurannya agar memiliki dimensi seragam dan efisien secara komputasi selama pelatihan. Proses segmentasi kemudian dilakukan untuk memisahkan objek utama dari latar belakang, sehingga sistem dapat mengenali karakteristik penyakit dengan lebih akurat. Hasil citra yang telah melalui tahap ini disimpan dalam format PNG untuk menjaga kualitas visual. Citra asli

berukuran 6000×4000 piksel dipotong menggunakan parameter $left = 2500$, $top = 1500$, $right = 3500$, dan $bottom = 2500$, menghasilkan ukuran akhir 1000×1000 piksel. Proses ini bertujuan menonjolkan subjek utama serta menghilangkan bagian gambar yang tidak diperlukan sebelum tahap augmentasi dan pelatihan model dilakukan.

3.3. Augmentasi Data

Setelah seluruh citra melalui proses pra-pemrosesan, tahap berikutnya adalah augmentasi data yang berfungsi untuk memperluas variasi *dataset* tanpa menambah jumlah data asli. Langkah ini sangat penting untuk meningkatkan kemampuan generalisasi model, terutama ketika data pelatihan berasal dari kondisi pencahayaan, sudut pandang, dan latar belakang yang beragam di lapangan.

Proses augmentasi dilakukan secara otomatis dengan memanfaatkan pustaka TensorFlow dan Keras melalui fungsi *ImageDataGenerator*. Setiap citra mengalami beberapa transformasi acak, seperti rotasi hingga 15° , pergeseran sudut pandang (*shear*) dan pembesaran (*zoom*) sekitar dua puluh persen, serta pembalikan arah secara horizontal. Selain itu, seluruh nilai piksel dinormalisasi kedalam rentang antara 0 hingga 1 agar model dapat beradaptasi lebih cepat selama proses pelatihan.

Dengan pendekatan ini, setiap citra asli dapat menghasilkan beberapa variasi baru yang tetap mempertahankan karakteristik penyakit pada daun tomat. Hasilnya, *dataset* menjadi lebih beragam dan representatif terhadap kondisi sebenarnya di lapangan. Proses augmentasi ini juga membantu mengurangi risiko *overfitting* dengan membuat model tidak terlalu bergantung pada pola citra tertentu.

3.4. Pembagian Data

Tahap pembagian data dilakukan untuk memastikan proses pelatihan, validasi, dan pengujian model berjalan secara objektif pada data yang tidak saling tumpang tindih. *Dataset* yang digunakan terdiri dari 5.967 citra dengan 9 kelas penyakit, masing-masing berjumlah 663 citra, sehingga distribusi awal *dataset* sudah seimbang. Pembagian *dataset* dilakukan menggunakan metode *stratified split*, agar distribusi tiap kelas tetap proporsional pada seluruh *subset*. Proporsi pembagian yang digunakan adalah 70% untuk data pelatihan, 20% untuk validasi, dan 10% untuk data pengujian. Persamaan (2), (3), (4) merupakan pembagian untuk total *dataset* sejumlah N .

$$D_{\{\text{train}\}} = 0,70 \times N \quad (2)$$

$$D_{\{\text{val}\}} = 0,20 \times N \quad (3)$$

$$D_{\{\text{test}\}} = 0,10 \times N \quad (4)$$

Dengan total dataset $N=5967$

$N=5967$, jumlah citra pada tiap *subset* diperoleh sebagai berikut:

$$D_{\{text{train}\}} = 0,70 \times 5967 = 4176.9 \approx 4177$$

$$D_{\{text{val}\}} = 0,20 \times 5967 = 1193.4 \approx 1193$$

$$D_{\{text{test}\}} = 0,10 \times 5967 = 596.7 \approx 597$$

Seluruh *subset* data diproses menggunakan ImageDataGenerator dengan konfigurasi yang sama seperti tahap augmentasi, termasuk normalisasi piksel ke rentang $[0,1]$ dan penyeragaman ukuran citra ke resolusi 224×224 piksel sesuai standar arsitektur EfficientNetB0. Pembagian data yang proporsional dan seimbang ini memastikan bahwa model belajar dari variasi data yang memadai, terhindar dari bias kelas, dan memungkinkan evaluasi performa yang lebih reliabel pada subset pengujian.

3.5. Arsitektur Model

Model yang digunakan dalam penelitian ini berbasis arsitektur EfficientNetB0, yaitu salah satu varian dari keluarga EfficientNet yang dirancang untuk mencapai keseimbangan optimal antara akurasi dan efisiensi komputasi. Arsitektur ini menggunakan prinsip *compound scaling*, dimana kedalaman, lebar, dan resolusi jaringan ditingkatkan secara proporsional untuk mendapatkan performa maksimal dengan jumlah parameter yang relatif kecil. Pendekatan ini sangat relevan untuk implementasi pada perangkat dengan sumber daya terbatas seperti *edge devices* atau sistem deteksi lapangan berbasis IoT.

Proses pengembangan model dilakukan dengan memanfaatkan *transfer learning* menggunakan bobot pra-latih (*pretrained weights*) dari *dataset* ImageNet. Pada tahap awal, seluruh lapisan dasar (*base model*) EfficientNetB0 dibekukan untuk mempertahankan kemampuan ekstraksi fitur umum yang telah diperoleh dari pelatihan sebelumnya. Selanjutnya, ditambahkan beberapa lapisan klasifikasi di bagian atas jaringan untuk menyesuaikan dengan kebutuhan klasifikasi penyakit daun tomat.

Struktur lapisan tambahan yang diterapkan terdiri dari Global Average Pooling 2D untuk mereduksi dimensi fitur, diikuti oleh lapisan *Dropout* dengan tingkat 0,3 sebagai upaya mengurangi risiko *overfitting*, dan lapisan Dense dengan aktivasi softmax yang memiliki sembilan neuron sesuai jumlah kelas penyakit yang digunakan dalam penelitian. Lapisan softmax ini menghasilkan nilai probabilitas untuk setiap kelas sehingga model dapat mengidentifikasi jenis penyakit berdasarkan nilai tertinggi yang diperoleh.

Proses pelatihan dilakukan menggunakan *optimizer* Adam dengan *learning rate* sebesar 0,001 serta fungsi kerugian (*loss function*) *categorical cross-entropy* karena permasalahan yang dihadapi merupakan

klasifikasi multikelas. Model dilatih menggunakan *batch size* 32 dan dijalankan selama beberapa *epoch* hingga konvergen. Untuk mencegah *overfitting*, diterapkan *callback EarlyStopping* yang secara otomatis menghentikan proses pelatihan ketika tidak terjadi peningkatan performa pada data validasi dalam sejumlah iterasi berturut-turut.

Arsitektur EfficientNetB0 dipilih karena kemampuannya menghasilkan akurasi tinggi dengan jumlah parameter relatif kecil, yaitu sekitar 5,3 juta parameter total, dimana 11.529 diantaranya merupakan parameter terlatih (*trainable parameters*) pada lapisan klasifikasi yang baru ditambahkan. Keunggulan ini menjadikan EfficientNetB0 sangat efisien dalam inferensi tanpa mengorbankan akurasi sehingga cocok diterapkan pada sistem cerdas berbasis *edge computing* untuk deteksi penyakit tanaman secara *real-time* di lapangan.

3.6. Proses Pelatihan dan Evaluasi model

Tahap pelatihan model dilakukan setelah seluruh *dataset* selesai melalui proses pra-pemrosesan, augmentasi, dan pembagian data. Proses ini bertujuan untuk mengoptimalkan bobot jaringan EfficientNetB0 agar mampu mengenali pola visual penyakit daun tomat secara akurat [31]

Pelatihan dilakukan menggunakan *optimizer* Adam dengan *learning rate* awal sebesar 0,001, yang memberikan keseimbangan baik antara kecepatan konvergensi dan stabilitas pembaruan bobot. Fungsi kerugian yang digunakan adalah *categorical cross-entropy* karena kasus klasifikasi yang dihadapi bersifat multikelas, sementara metrik evaluasi utama yang dipantau adalah akurasi pada data pelatihan dan validasi.

Selama pelatihan, digunakan *batch size* sebesar 32 dengan jumlah *epoch* maksimum sebanyak 50, disertai penerapan *callback EarlyStopping* untuk menghentikan proses pelatihan secara otomatis ketika performa validasi tidak menunjukkan peningkatan signifikan dalam 10 iterasi berturut-turut. Pendekatan ini membantu mencegah terjadinya *overfitting* serta memastikan model berhenti pada titik konvergensi optimal.

Selama proses pelatihan, kurva akurasi dan kehilangan (*loss*) dipantau untuk mengevaluasi kestabilan dan performa model. Berdasarkan hasil pengamatan, nilai akurasi pelatihan meningkat secara konsisten hingga mencapai stabilitas, sementara nilai *loss* menurun signifikan pada setiap *epoch*. Model terbaik disimpan dalam format .h5 menggunakan *callback ModelCheckpoint* agar hasil optimal dapat digunakan pada tahap pengujian berikutnya.


Setelah proses pelatihan selesai, model diuji menggunakan *data testing* yang tidak pernah digunakan

sebelumnya. Hasil evaluasi menunjukkan bahwa model EfficientNetB0 yang telah dilatih mampu mencapai akurasi sebesar 89%, dengan nilai *macro average* dan *weighted average* masing-masing mencapai 90%. Selain itu, analisis *confusion matrix* memperlihatkan bahwa sebagian besar kelas penyakit dapat diklasifikasikan dengan tingkat kesalahan yang rendah, terutama pada kelas *Early Blight* dan *Bacterial Spot* yang memiliki fitur visual serupa.


Gambar 12 dan 13 menampilkan grafik akurasi dan *loss* dari dua tahap pelatihan model EfficientNetB0, yaitu tahap *transfer learning* awal (Stage 1) dan tahap *fine-tuning*. Garis vertikal putus-putus berwarna hitam menandai titik dimulainya proses *fine-tuning*.

Grafik *Combined Accuracy* terlihat bahwa selama tahap pertama (Stage 1) baik akurasi pelatihan maupun validasi mengalami peningkatan signifikan dari awal hingga mendekati *epoch* ke-20. Kurva akurasi pelatihan (garis merah putus-putus) dan akurasi validasi (garis hijau putus-putus) menunjukkan pola yang hampir sejajar, menandakan bahwa model mampu belajar secara stabil tanpa *overfitting*. Setelah memasuki tahap *fine-tuning*, akurasi kembali meningkat secara bertahap pada kedua *dataset* hingga mencapai nilai mendekati 0,93 pada akhir pelatihan. Hal ini menunjukkan bahwa pembukaan sebagian lapisan EfficientNetB0 untuk penyesuaian ulang bobot memberikan kontribusi positif terhadap peningkatan performa model.

Grafik *Combined Loss* memperlihatkan pola penurunan *loss* yang konsisten seiring bertambahnya *epoch*. Pada tahap pertama, nilai *loss* pada data pelatihan maupun validasi menurun tajam hingga mencapai stabilitas di sekitar *epoch* ke-18. Selama proses *fine-tuning*, *loss* kembali turun secara perlahan pada kedua *subset* data dengan selisih yang kecil antara kurva pelatihan (merah) dan validasi (hijau). Hal ini menunjukkan bahwa model tidak mengalami *overfitting* dan mampu mempertahankan keseimbangan antara kemampuan pembelajaran dan generalisasi.



Gambar 12 Grafik Hasil Pelatihan



Gambar 13. Grafik hasil dari Kombinasi

Secara keseluruhan, kedua grafik menunjukkan bahwa strategi pelatihan dua tahap memberikan hasil yang optimal. Tahap *transfer learning* berperan penting dalam mempercepat konvergensi awal dengan memanfaatkan bobot pra-latih dari ImageNet, sedangkan tahap *fine-tuning* meningkatkan sensitivitas model terhadap fitur spesifik daun tomat yang terdapat pada *dataset* penelitian ini. Kombinasi keduanya menghasilkan model yang stabil, akurat, dan efisien dalam mengenali pola visual penyakit tanaman.

Temuan ini membuktikan bahwa penerapan arsitektur EfficientNetB0 dengan pendekatan *transfer learning* efektif untuk klasifikasi penyakit daun tomat berbasis citra. Kombinasi antara proses augmentasi data yang optimal, mekanisme *fine-tuning* pada lapisan atas, serta strategi pelatihan berbasis *early stopping* memberikan hasil yang efisien secara komputasi tanpa mengorbankan akurasi.

3.7. Hasil dan Pembahasan


Hasil penelitian ini menunjukkan performa model klasifikasi penyakit daun tomat berbasis arsitektur EfficientNetB0 yang telah dioptimalkan melalui proses pra-pemrosesan, augmentasi data, dan pelatihan model secara bertahap. Proses pelatihan dilakukan selama beberapa *epoch* dengan penerapan mekanisme *early stopping* untuk memastikan stabilitas konvergensi serta mencegah *overfitting*.

Selama proses pelatihan, nilai akurasi pada data pelatihan meningkat secara konsisten dari *epoch* awal hingga mencapai titik stabil pada kisaran 0,89. Pada saat yang sama, nilai *loss* mengalami penurunan signifikan dan berhenti menurun ketika model mulai mencapai kestabilan. Hasil ini menunjukkan bahwa model telah belajar secara optimal tanpa kehilangan kemampuan generalisasi terhadap data baru. Kurva akurasi dan *loss* antara data pelatihan dan validasi yang relatif sejajar menandakan bahwa model memiliki keseimbangan yang baik antara kompleksitas jaringan dan kapasitas *dataset*.

Tabel 1. Hasil Pemodelan


	precision	recall	f1-score	support
Bacterial_spot	0,94	0,88	0,91	34
Blossom_End_Rot	0,84	0,91	0,87	34
Early_blight	0,96	0,68	0,79	34
Late_blight	0,91	0,94	0,93	34
Rotten_Tomat	0,91	0,88	0,90	34
Septoria_leaf_spot	0,70	0,97	0,81	34
Spotted_Wilt_Virus	0,93	0,76	0,84	34
Tomato_Anthr	0,89	0,97	0,93	34
Tomato_Yello	1,00	0,97	0,99	34
w_Leaf_Curl_Virus				
Accuracy			0,89	306
Macro avg	0,90	0,89	0,89	306
Weighted avg	0,90	0,89	0,89	306

Evaluasi performa seperti terlihat pada Tabel 1 dilakukan menggunakan data uji yang sepenuhnya terpisah dari proses pelatihan. Hasil pengujian menunjukkan bahwa model mencapai akurasi keseluruhan sebesar 89%, yang berarti bahwa 89% dari seluruh citra pada data uji berhasil diklasifikasikan dengan benar oleh model. Selain itu, model memperoleh *macro average* sebesar 90%, yaitu rata-rata performa (*precision*, *recall*, atau *F1-score*) yang dihitung secara merata untuk setiap kelas tanpa mempertimbangkan jumlah sampelnya, sehingga menunjukkan bahwa semua kelas penyakit diperlakukan setara oleh model. Sementara itu, *weighted average* sebesar 90% menunjukkan bahwa angka rata-rata performa dihitung dengan mempertimbangkan proporsi jumlah sampel pada setiap kelas, sehingga mencerminkan performa model secara realistis berdasarkan distribusi data asli. Konsistensi nilai *macro* dan *weighted average* menegaskan bahwa model mampu mengenali pola visual penyakit secara merata tanpa bias terhadap kelas tertentu.



Gambar 14. Merupakan grafik *Confusion Matrix*

Analisis lebih lanjut seperti terlihat pada Gambar 14 terhadap *confusion matrix* menunjukkan bahwa sebagian besar kelas penyakit, seperti *Early Blight*, *Late Blight*, *Septoria Leaf Spot*, dan *Bacterial Spot*, dapat diklasifikasikan dengan benar. Beberapa kesalahan klasifikasi masih terjadi antara kelas *Septoria Leaf Spot* dan *Bacterial Spot*, yang memiliki pola bercak daun mirip pada area tepi daun, namun perbedaannya relatif kecil. Kesalahan ini dapat diminimalkan pada penelitian lanjutan dengan memperluas variasi data lapangan dan menerapkan metode *feature enhancement* tambahan.



Gambar 15. Merupakan hasil Training and Validation Accuracy

Selain akurasi, metrik lain seperti *precision*, *recall*, dan *F1-score* juga digunakan untuk memberikan gambaran lebih komprehensif mengenai kinerja model. Hasil evaluasi menunjukkan bahwa nilai *F1-score* rata-rata mencapai lebih dari 0,88, menandakan keseimbangan yang baik antara ketepatan dan sensitivitas model dalam mengenali setiap kelas penyakit seperti terlihat pada Gambar 15. Keunggulan utama penggunaan EfficientNetB0 terlihat pada efisiensi komputasi dan ukuran parameter yang relatif kecil. Dengan total sekitar 5,3 juta parameter dan hanya sebagian kecil yang dapat dilatih (*trainable*), model ini mampu berjalan cepat dengan konsumsi sumber daya yang rendah. Hal ini menjadikannya sangat potensial untuk diimplementasikan pada perangkat lapangan seperti *Raspberry Pi*, *smartphone*, atau sistem IoT untuk deteksi penyakit tanaman secara *real-time*. Secara keseluruhan, hasil yang diperoleh membuktikan bahwa kombinasi antara *transfer learning*, augmentasi data yang tepat, dan arsitektur EfficientNetB0 mampu menghasilkan sistem klasifikasi yang akurat dan efisien. Temuan ini memberikan dasar kuat bagi pengembangan sistem deteksi dini penyakit tanaman tomat yang tidak hanya bekerja di lingkungan laboratorium, tetapi juga dapat diadaptasikan untuk kondisi lapangan yang sebenarnya.

4. Kesimpulan

Penelitian ini menciptakan model klasifikasi penyakit pada tanaman tomat yang menggunakan gambar daun dengan arsitektur EfficientNetB0, yang terbukti efektif dan tepat untuk mengenali berbagai jenis penyakit pada daun tomat. Dengan memanfaatkan metode diatas, model tersebut dapat meraih akurasi mencapai 89%, serta mendapatkan nilai makro rata-rata dan rata-rata berbobot masing-masing sebesar 90%, yang

mencerminkan kinerja yang konsisten dan terpercaya. Temuan ini menegaskan bahwa EfficientNetB0 menawarkan keseimbangan yang ideal antara ketepatan dan efisiensi dalam komputasi, sehingga sangat cocok untuk diterapkan dalam sistem deteksi dini di lapangan. Diharapkan penelitian ini dapat mempercepat, meningkatkan keakuratan, dan mengotomatiskan proses deteksi penyakit tanaman bagi petani, Secara keseluruhan, studi ini memberikan kontribusi yang signifikan dalam pengaplikasian pertanian presisi yang didukung oleh kecerdasan buatan, terutama pada komoditas hortikultura seperti tomat, serta membuka jalan bagi pengembangan sistem pemantauan tanaman yang pintar, adaptif, dan berkelanjutan di masa depan.

Daftar Rujukan

- [1] W. Food, *World Food and Agriculture – Statistical Yearbook 2023*. 2023.
- [2] S. U. Haj, R. T. Adek, and R. Suwanda, “Implementasi Sistem Irigasi Berbasis Internet of Things (IoT) Untuk Optimasi Penggunaan Air Pada Pertanian,” pp. 338–347, 2025.
- [3] J. Ham, “Regulasi Regenerasi Petani dalam Konteks Ketahanan Pangan: Sebuah Upaya dan Jaminan Perlindungan Hak Atas Pangan,” no. May, 2022.
- [4] M. Pengelolaan dan K. Epidemik, “PENGENDALIAN PENYAKIT TANAMAN PADI BERWAWASAN LINGKUNGAN MELALUI PENGELOLAAN KOMPONEN EPIDEMIK Control of Environmentally-Based Rice Disease Through the Management of Epidemic Components,” 2018.
- [5] J. Lloret, “Edge Computing in Precision agriculture,” no. December 2022, pp. 1–1, 2023.
- [6] S. Parthasarathy, P. Lakshmi Devi, V. K. Satya, and C. Gopalakrishnan, *Plant Pathology and Disease Management*, no. November. 2023.
- [7] P. Ritchie, Hannah; Roser, Max; Rosado, “Tomato production (FAO, 2023),” *Global Change Data Lab, University of Oxford*, 2025. .
- [8] R. Rusnam, R. A. Surya, and M. Makky, “Water Stress Influence For Tomato (Solanum Lycopersicum) Production,” *Andalasian Int. J. Agric. Nat. Sci.*, vol. 2, no. 01, pp. 25–37, 2021.
- [9] T. Sudaryanto, M. Iqbal, R. Kustiari, S. K. Dermoredjo, and C. Muslim, “TINGKAT DUKUNGAN DOMESTIK UNTUK SEKTOR PERTANIAN INDONESIA Domestic Supports to Agriculture Sector in Indonesia,” vol. 14, no. 1, pp. 73–82, 2016.
- [10] N. Hadiyanti, R. T. Probojati, and R. N. Prayoga, “Budidaya Tanaman Hortikultura Sistem Hidroponik untuk Menarik Minat Generasi Muda dalam Bidang Pertanian (Cultivation of Horticultural Plants Using Hydroponic System to Attract the Interest of the Younger Generation in the Field of Agriculture),” *Agrokreatif J. Ilm. Pengabd. Kpd. Masyarakat*, vol. 11, no. 1, pp. 11–19, 2025.
- [11] D. T. P. dan H. P. J. Barat, “Produktivitas Tomat Berdasarkan Kabupaten/Kota di Jawa Barat,” *Pemerintah Provinsi Jawa Barat*, 2024. .
- [12] E. Nova Rahmawati, T. Pinandita, M. Ayu Fitriani, and E. Ambar Pambudi, “Deteksi Penyakit Daun Tomat Real-Time pada Platform Android Berbasis Convolutional Neural Network,” *J. Pendidik. dan Teknol. Indones.*, vol. 5, no. 8, pp. 2402–2415, 2025.
- [13] M. A. Altieri, C. I. Nicholls, G. Dinelli, and L. Negri, “Towards an agroecological approach to crop health: reducing pest incidence through synergies between plant diversity and soil microbial ecology,” *npj Sustain. Agric.*, vol. 2, no. 1, pp. 2–7, 2024.
- [14] W. O. Mardiana, N. A., & Windari, “G-Tech : Jurnal Teknologi Terapan,” *G-Tech J. Teknol. Terap.*, vol. 8, no. 1, pp. 186–195, 2024.
- [15] A. Halder, S. Guha Neogi, S. Dutta, K. Khamaru, A. Bhattacharya, and S. Roy, “Early Detection and Classification of Tomato Leaf Blight Disease Using Deep Neural Networks,” *2nd IEEE Int. Conf. Data Sci. Netw. Secur. ICDSNS 2024*, 2024.
- [16] W. Fithratul Zalmi, P. Hari Saputro, J. Sitanggang, and K. Leatemia, “Penerapan Convolutional Neural Network (CNN) untuk Klasifikasi Penyakit Daun Tomat,” *Inform. J. Ilmu Komput.*, vol. 21, no. 2, pp. 58–68, 2025.
- [17] N. Marcin, R. F. Majid, N. Marzena, and U. K. Elzbieta, “An overview of pathology and resistance breeding,” *Plant Dis.*, vol. 96, no. 1, pp. 4–17, 2012.
- [18] A. Saeed, A. A. Abdel-Aziz, A. Mossad, M. A. Abdelhamid, A. Y. Alkhaled, and M. Mayhoub, “Smart Detection of Tomato Leaf Diseases Using Transfer Learning-Based Convolutional Neural Networks,” *Agric.*, vol. 13, no. 1, 2023.
- [19] H. Sun *et al.*, “Efficient deep learning - based tomato leaf disease detection through global and local feature fusion,” *BMC Plant Biol.*, 2025.
- [20] S. Desai, S. Ghewade, D. Girge, and M. Gajare, “Real-Time Leaf Disease Detection Using CNN on Raspberry Pi for Precision Agriculture,” pp. 549–553, 2025.
- [21] Z. Tang *et al.*, “A Precise Image-Based Tomato Leaf Disease Detection Approach Using PLPNet,” *Plant Phenomics*, vol. 5, pp. 1–18, 2023.
- [22] S. U. Islam, G. Ferraioli, and V. Pascasio, “Tomato Leaf Detection, Segmentation, and Extraction in Real-Time Environment for Accurate Disease Detection,” *AgriEngineering*, vol. 7, no. 4, pp. 1–16, 2025.
- [23] M. S. Islam *et al.*, “Multimodal Hybrid Deep Learning Approach to Detect Tomato Leaf Disease Using Attention Based Dilated Convolution Feature Extractor with Logistic Regression Classification,” *Sensors*, vol. 22, no. 16, pp. 1–31, 2022.
- [24] J. Thirunavukkarasu, K. J. Oindrilla, M. Sangeetha, and E. Swetha, “An Efficient Deep Learning Approach for Plant Disease Detection,” *Proc. 2022 Int. Conf. Innov. Comput. Intell. Commun. Smart Electr. Syst. ICSES 2022*, no. July 2022, 2022.
- [25] V. Godase, S. Technical, and E. Society, “LoRaEdge-ESP32 Synergy: Revolutionizing Farm Weather Data Collection with Low-Power, Long-Range IoT,” no. July, 2025.
- [26] G. Jean, “Multimodal Vision-Language Models for Early Pest and Disease Detection,” no. July, 2025.
- [27] Y. Mardianto, T. Dewi, and P. Risma, “Analisis Klasifikasi Kematangan Buah Tomat dengan Pendekatan Transfer Learning Model EfficientNet,” vol. 11, no. 1, pp. 20–25, 2024.
- [28] R. Ingle, A. K. Shahade, M. Gaikwad, and S. Patil, “MethodsX Deep learning driven silicon wafer defect segmentation and classification,” *MethodsX*, vol. 14, no. December 2024, p. 103158, 2025.
- [29] S. Rustad, G. F. Shidik, A. Syukur, C. Science, U. D. Nuswantoro, and U. N. Mandiri, “COMPARATIVE ANALYSIS OF CNN ARCHITECTURES FOR TOMATO LEAF,” vol. 11, no. 1, pp. 125–135, 2025.
- [30] J. Han, U. of I. at Urbana–Champaign, M. Kamber, J. Pei, and S. F. University, *DataMining*. 2012.