

BAB I

PENDAHULUAN

1.1 Latar Belakang

Tomat telah menjadi salah satu komoditas dengan nilai ekonomi internasional yang tinggi. Secara global, produksi tomat dunia mencapai lebih dari 180 juta ton per tahun dan menunjukkan tren peningkatan dalam satu dekade terakhir, menjadikannya salah satu komoditas sayuran dengan volume produksi tertinggi di dunia. Negara-negara seperti Tiongkok, India, dan Turki menjadi produsen utama yang berkontribusi signifikan terhadap pasokan global. Tingginya volume produksi tersebut mencerminkan pentingnya tomat dalam mendukung ketahanan pangan serta industri pengolahan pangan dunia [1].

Di Indonesia, tomat dibudidayakan hampir di seluruh provinsi dan menjadi salah satu komoditas utama subsektor hortikultura. Berdasarkan data Badan Pusat Statistik (BPS), luas panen tomat nasional pada tahun 2021 tercatat sebesar 59.401,23 hektar, meningkat menjadi 63.369 hektar pada tahun 2022, kemudian menurun menjadi 61.255 hektar pada tahun 2023, lalu menurun menjadi 58.995,13 hektar pada tahun 2024, dan akhirnya menurun menjadi 54.989,14 hektar pada tahun 2025 [2]. Provinsi dengan luas panen terbesar antara lain Jawa Barat, Jawa Timur, Jawa Tengah, Sumatera Utara, dan Sulawesi Selatan. Fluktuasi luas panen tersebut menunjukkan adanya dinamika produksi yang dapat dipengaruhi oleh berbagai faktor seperti kondisi iklim, distribusi pasar, serta serangan organisme pengganggu tanaman.

Meskipun luas panen relatif tinggi, produktivitas tomat sangat rentan terhadap serangan penyakit tanaman. Penyakit seperti *Early Blight* dan *Late Blight* diketahui sebagai ancaman global terhadap budidaya tomat. *Early Blight* merupakan penyakit yang terjadi karena tumbuhnya jamur *Alternaria solani* dan ditandai dengan munculnya bercak cokelat konsentris pada daun yang dapat menyebabkan defoliasi dini, sedangkan *Late Blight* disebabkan oleh patogen *Phytophthora infestans* yang bersifat lebih agresif dan mampu berkembang cepat

pada kondisi lingkungan lembap. *Late Blight* dapat menyebabkan kerusakan jaringan daun dan buah secara cepat serta berpotensi menurunkan hasil panen hingga 80% pada kondisi epidemi berat [3]. Infeksi patogen ini tidak hanya merusak struktur daun, tetapi juga mengganggu proses fisiologis tanaman termasuk fotosintesis, sehingga mempercepat penurunan pertumbuhan dan produktivitas tanaman[4]. Serangan penyakit yang tidak terdeteksi secara dini dapat menyebabkan penurunan kualitas dan kuantitas hasil panen secara signifikan, sehingga berimplikasi pada kerugian ekonomi bagi petani serta mengancam stabilitas produksi pangan [3].

Identifikasi penyakit daun tomat secara tradisional pada umumnya dilakukan dengan cara mengamati gejala visual pada tanaman oleh petani maupun ahli pertanian. Akan tetapi, pendekatan ini memiliki keterbatasan seperti subjektivitas penilaian, keterbatasan jumlah pakar, serta kesulitan membedakan gejala penyakit yang memiliki karakteristik visual serupa. Selain itu, kondisi lapangan yang bervariasi seperti perubahan suhu, kelembapan, dan intensitas Cahaya diketahui sangat memengaruhi perkembangan penyakit hawar daun serta variasi tampilan visual gejala pada daun [3]. Variabilitas tersebut menjadi tantangan tambahan dalam proses identifikasi penyakit secara manual, terutama pada tahap awal infeksi. Penelitian terbaru menunjukkan bahwa integrasi sistem berbasis citra dan *machine learning* dapat meningkatkan akurasi deteksi penyakit dan membantu proses identifikasi secara lebih objektif dan konsisten dibandingkan metode konvensional [5].

Dengan berkembangnya *Deep learning* dalam bidang *Computer vision*, memberikan peluang untuk mengotomatisasi proses klasifikasi penyakit tanaman berbasis citra. Penerapan *deep learning* dalam pertanian telah menunjukkan peningkatan akurasi deteksi penyakit dibandingkan metode tradisional [6]. Sejalan dengan transformasi digital nasional, sektor pertanian mulai mengadopsi konsep smart agriculture yang memanfaatkan teknologi digital seperti IoT dan kecerdasan buatan untuk meningkatkan efisiensi serta produktivitas pertanian [6], [7]. Sistem klasifikasi penyakit berbasis citra yang memiliki kebutuhan komputasi relatif

ringan berpotensi untuk diimplementasikan pada berbagai platform digital guna mendukung deteksi dini penyakit di lapangan.

Berbagai penelitian sebelumnya menunjukkan bahwa arsitektur *Convolutional Neural Network* (CNN) seperti EfficientNet mampu mencapai performa yang sangat baik pada klasifikasi penyakit tanaman. Penelitian [8] melaporkan bahwa EfficientNet-B0 memperoleh akurasi sebesar 98,51% pada tugas klasifikasi penyakit tanaman multi-kelas. Hasil serupa juga ditunjukkan pada penelitian [9], dimana EfficientNet-B4 dan EfficientNet-B5 mampu mencapai akurasi di atas 99% pada dataset yang telah melalui proses augmentasi. Temuan tersebut menunjukkan bahwa arsitektur CNN masih menjadi salah satu pendekatan yang efektif dalam klasifikasi penyakit tanaman berbasis citra. Di sisi lain, arsitektur berbasis *Transformer* seperti *Vision Transformer* (ViT) diperkenalkan dengan kemampuan menangkap hubungan global antar bagian citra melalui mekanisme *self-attention* [10]. Pengembangan lebih lanjut menghasilkan model *hybrid* seperti FastViT yang mampu menggabungkan efisiensi komputasi CNN dengan kemampuan representasi global *Transformer*, serta menunjukkan performa yang kompetitif dengan kecepatan inferensi yang lebih tinggi dibandingkan beberapa model CNN konvensional [11]. Meskipun demikian, sebagian besar penelitian terdahulu masih berfokus pada peningkatan akurasi klasifikasi dan penggunaan augmentasi sebagai teknik peningkatan data pelatihan. Meskipun demikian, sebagian besar penelitian terdahulu masih berfokus pada peningkatan akurasi klasifikasi dan penggunaan augmentasi sebagai teknik peningkatan data pelatihan. EfficientNet dan FastViT sama-sama memanfaatkan operasi konvolusi (*convolution*) untuk mengekstraksi fitur visual dari citra, namun keduanya memiliki mekanisme pemrosesan fitur yang berbeda. EfficientNet mengandalkan representasi fitur berbasis CNN, sedangkan FastViT mengombinasikan konvolusi dengan mekanisme Transformer untuk menangkap hubungan lokal dan global secara lebih efektif. Perbedaan karakteristik tersebut menjadikan kedua arsitektur menarik untuk dibandingkan, khususnya dalam mengevaluasi ketahanan (*robustness*) terhadap berbagai variasi kondisi visual.[8], [9]

Beberapa penelitian telah memanfaatkan kombinasi berbagai teknik *data augmentation* untuk meningkatkan kemampuan generalisasi dan *robustness* model. Huang dkk. menggunakan *random augmentation* yang dipadukan dengan *consistency regularization* melalui metode **DAIR**[10], sedangkan penelitian lain mengombinasikan transformasi *affine*, *perspective*, dan citra sintetis berbasis **C-GAN** untuk meningkatkan performa model klasifikasi penyakit daun tomat. Meskipun pendekatan tersebut menunjukkan hasil yang baik, evaluasi masih dilakukan terhadap kombinasi augmentasi secara keseluruhan. Oleh karena itu, masih diperlukan penelitian yang mengevaluasi pengaruh jenis augmentasi secara individual terhadap *robustness* model[11].

Pada penelitian ini dilakukan analisis komparatif untuk mengatasi keterbatasan penelitian sebelumnya yang umumnya hanya berfokus pada pengukuran akurasi model pada kondisi citra ideal tanpa mengevaluasi ketahanan (*robustness*) model terhadap variasi visual. Dalam praktiknya, proses akuisisi citra di lapangan sering dipengaruhi oleh berbagai faktor seperti perubahan pencahayaan, distorsi geometris, maupun gangguan visual lainnya yang dapat memengaruhi performa model klasifikasi. Berbagai penelitian telah menunjukkan bahwa penerapan *deep learning* dalam bidang pertanian mampu meningkatkan kemampuan deteksi penyakit tanaman secara otomatis melalui analisis citra daun [6], [12]. Namun demikian, sebagian besar studi terdahulu belum secara sistematis membandingkan performa arsitektur berbasis *Convolutional Neural Network* (CNN) dan arsitektur hibrida CNN–Transformer dalam menghadapi variasi kondisi visual tersebut. Oleh karena itu, diperlukan penelitian yang secara terstruktur mengevaluasi ketahanan model terhadap gangguan visual yang terkontrol. Penelitian ini melakukan analisis perbandingan *robustness* antara EfficientNet-B0 dan FastViT dalam klasifikasi penyakit daun tomat menggunakan Tomato Leaves *Dataset* yang terdiri dari 9 kelas penyakit dan 1 kelas daun sehat. EfficientNet-B0 dipilih karena merupakan arsitektur CNN yang efisien dengan pendekatan *compound scaling* yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan sehingga mampu mencapai performa tinggi dengan kompleksitas parameter yang relatif rendah [13]. Sementara itu, FastViT sebagai arsitektur hibrida CNN–

Transformer dirancang untuk menggabungkan kemampuan ekstraksi fitur lokal dari CNN dengan mekanisme *self-attention* yang mampu memodelkan hubungan global antar bagian citra [9], [14]. Pendekatan berbasis Transformer diketahui memiliki potensi yang baik dalam meningkatkan kemampuan generalisasi model terhadap variasi data visual. Oleh karena itu, perbandingan kedua arsitektur ini menjadi penting untuk mengetahui sejauh mana pendekatan konvolusional murni dan pendekatan berbasis *attention mechanism* dapat memberikan ketahanan performa pada kondisi citra yang beragam.

Evaluasi dalam penelitian ini dilakukan melalui penerapan augmentasi citra secara individual, meliputi *Brightness*, *Contrast*, *Saturation*, *Hue*, *Affine*, *Perspective*, dan *Blur*. Teknik augmentasi telah banyak digunakan untuk meningkatkan kemampuan generalisasi model serta menguji ketahanan model terhadap variasi visual pada data citra. Melalui pendekatan ini, penelitian diharapkan dapat memberikan pemahaman yang lebih komprehensif mengenai karakteristik performa dan *robustness* model, serta memberikan insight mengenai arsitektur yang lebih sesuai untuk implementasi pada sistem pertanian digital maupun perangkat dengan keterbatasan sumber daya komputasi.

Berdasarkan uraian tersebut, penelitian ini memberikan beberapa kontribusi ilmiah. Pertama, penelitian ini melakukan analisis perbandingan antara arsitektur berbasis *Convolutional Neural Network* (CNN), yaitu EfficientNet-B0, dan arsitektur *hybrid* CNN–Transformer, yaitu FastViT-T8, pada tugas klasifikasi penyakit daun tomat. Kedua, evaluasi tidak hanya difokuskan pada akurasi klasifikasi, tetapi juga pada aspek *robustness* model terhadap berbagai variasi kondisi visual. Ketiga, penelitian ini menggunakan augmentasi citra secara individual sebagai instrumen evaluasi sehingga pengaruh masing-masing gangguan visual, seperti *brightness*, *contrast*, *saturation*, *hue*, *affine*, *perspective*, dan *blur*, dapat dianalisis secara terpisah. Pendekatan ini berbeda dengan sebagian besar penelitian terdahulu yang menggunakan augmentasi terutama sebagai teknik peningkatan data pelatihan. Keempat, penelitian ini memanfaatkan berbagai metrik evaluasi *robustness* seperti *Mean Drop*, *Worst Drop*, *Standard Deviation Drop*, *Robustness score*, *Mean Latency*, dan *Mean Confidence Score* untuk memberikan

analisis yang lebih komprehensif terhadap karakteristik kedua model. Selain itu, penelitian ini juga mengimplementasikan model dalam bentuk demo aplikasi berbasis web menggunakan Gradio sebagai demonstrasi penggunaan model secara interaktif.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan sebelumnya, penelitian ini berfokus pada analisis performa dan *robustness* model *deep learning* untuk klasifikasi penyakit daun tomat pada berbagai kondisi visual. Adapun rumusan masalah yang akan dibahas dalam penelitian ini adalah sebagai berikut.

- 1 Bagaimana performa akurasi dan efisiensi model EfficientNet-B0 dan FastViT dalam klasifikasi penyakit daun tomat?
- 2 Bagaimana tingkat *robustness* EfficientNet-B0 dan FastViT-T8 terhadap berbagai gangguan visual yang disimulasikan melalui augmentasi individual berdasarkan metrik *Mean Accuracy*, *Mean Drop*, *Worst accuracy*, *Robustness score*, dan *Area Under Robustness Curve (AURC)*?
- 3 Jenis variasi kondisi visual manakah yang paling memengaruhi penurunan performa pada masing-masing model?
- 4 Model manakah yang lebih sesuai untuk implementasi sistem klasifikasi penyakit daun tomat dengan mempertimbangkan performa klasifikasi serta *robustness* terhadap variasi visual?

1.3 Batasan Masalah

Agar penelitian dapat dilakukan secara terarah dan sesuai dengan ruang lingkup yang ditetapkan, diperlukan beberapa batasan yang menjadi acuan dalam pelaksanaan penelitian. Batasan masalah yang digunakan dalam penelitian ini adalah sebagai berikut.

- 1 *Dataset* yang digunakan terdiri dari 9 kelas penyakit dan 1 kelas daun sehat.
- 2 Model yang dibandingkan dalam penelitian ini hanya EfficientNet-B0 dan FastViT.

- 3 Evaluasi dilakukan pada tugas klasifikasi citra daun, tidak mencakup segmentasi atau deteksi objek.
- 4 Variasi kondisi visual diterapkan melalui augmentasi individual yang meliputi *Brightness*, *Contrast*, *Saturation*, *Hue*, *Affine*, *Perspective*, dan *Blur*, tanpa menggunakan metode augmentasi otomatis seperti RandAugment atau AutoAugment.
- 5 Pengujian dilakukan menggunakan perangkat desktop, bukan pada implementasi langsung di perangkat mobile atau sistem tertanam.
- 6 Parameter evaluasi difokuskan pada metrik performa seperti akurasi, stabilitas performa terhadap variasi data, serta efisiensi komputasi (misalnya waktu inferensi dan jumlah parameter model).
- 7 Penelitian hanya difokuskan pada klasifikasi citra daun tomat sehingga hasil yang diperoleh belum dapat digeneralisasikan untuk identifikasi penyakit pada bagian tanaman lain seperti batang, buah, bunga, maupun akar.

1.4 Tujuan dan Manfaat Penelitian

1.4.1 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah ditetapkan, penelitian ini memiliki beberapa tujuan yang ingin dicapai. Tujuan penelitian tersebut adalah sebagai berikut.

- 1 Membandingkan performa akurasi, stabilitas, dan efisiensi antara EfficientNet-B0 dan FastViT dalam klasifikasi penyakit daun tomat.
- 2 Mengevaluasi tingkat *robustness* kedua model terhadap variasi kondisi visual melalui penerapan augmentasi individual.
- 3 Menganalisis sensitivitas model terhadap berbagai jenis gangguan visual melalui augmentasi untuk memahami karakteristik ketahanan masing-masing model.
- 4 Mengimplementasikan model klasifikasi penyakit daun tomat ke dalam aplikasi berbasis web menggunakan Gradio untuk mendemonstrasikan penggunaan model secara interaktif.

1.4.2 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat baik dari sisi teoritis maupun praktis. Manfaat teoritis berkaitan dengan kontribusi penelitian terhadap pengembangan ilmu pengetahuan, sedangkan manfaat praktis berkaitan dengan penerapan hasil penelitian pada bidang yang relevan. Adapun manfaat penelitian yang diharapkan adalah sebagai berikut.

1.4.2.1 Manfaat Teoritis

Secara teoritis, penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan kajian ilmiah di bidang *computer vision*, *deep learning*, dan klasifikasi penyakit tanaman berbasis citra. Adapun manfaat teoritis yang diharapkan adalah sebagai berikut.

- 1 Memberikan kontribusi ilmiah dalam kajian perbandingan arsitektur CNN dan *hybrid* CNN–Transformer pada klasifikasi penyakit tanaman, khususnya dalam aspek evaluasi robustness terhadap variasi kondisi visual secara individual.
- 2 Menambah referensi akademik mengenai karakteristik robustness arsitektur CNN dan Transformer pada tugas klasifikasi penyakit daun tomat.

1.4.2.2 Manfaat Praktis

Secara praktis, penelitian ini diharapkan dapat memberikan manfaat bagi pengembangan sistem klasifikasi penyakit tanaman berbasis citra serta menjadi referensi dalam penerapan teknologi pertanian digital. Adapun manfaat praktis yang diharapkan adalah sebagai berikut.

- 1 Memberikan rekomendasi model yang lebih stabil dan efisien untuk diterapkan dalam sistem klasifikasi penyakit tanaman berbasis citra.
- 2 Menjadi referensi dalam pengembangan aplikasi klasifikasi penyakit daun tomat berbasis web maupun platform digital lainnya.
- 3 Menyediakan *proof of concept* berupa demo aplikasi berbasis web yang dapat menjadi dasar pengembangan sistem klasifikasi penyakit daun tomat pada penelitian selanjutnya.

- 4 Berpotensi mendukung petani, penyuluh pertanian, maupun masyarakat yang membudidayakan tanaman tomat dalam melakukan identifikasi awal penyakit daun apabila sistem ini dikembangkan lebih lanjut menjadi aplikasi yang siap digunakan.

1.5 Sistematika Penulisan

BAB I – PENDAHULUAN

Bab ini membahas latar belakang permasalahan yang mendasari penelitian, yaitu pentingnya klasifikasi penyakit daun tomat secara otomatis menggunakan pendekatan *deep learning*. Selain itu, bab ini menjelaskan rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, serta sistematika penulisan yang digunakan dalam penyusunan tugas akhir.

BAB II – LANDASAN TEORI

Bab ini memuat kajian penelitian terdahulu yang relevan serta landasan teori yang mendukung penelitian. Teori yang dibahas meliputi penyakit daun tomat, *computer vision*, *deep learning*, *Convolutional Neural Network (CNN)*, *Vision Transformer*, *EfficientNet*, *FastViT*, teknik augmentasi citra, *robustness evaluation*, serta metrik evaluasi yang digunakan dalam penelitian.

BAB III – METODOLOGI PENELITIAN

Bab ini menjelaskan metodologi penelitian yang digunakan berdasarkan framework CRISP-DM. Pembahasan meliputi proses pengumpulan dan penggabungan dataset, pra-pemrosesan data, penerapan augmentasi citra, perancangan model *EfficientNet-B0* dan *FastViT-T8*, proses pelatihan model, skenario pengujian *robustness*, serta metode evaluasi yang digunakan untuk membandingkan performa kedua model.

BAB IV – ANALISIS DAN HASIL PENELITIAN

Bab ini menyajikan hasil implementasi dan pengujian model yang dilakukan pada *clean dataset* maupun berbagai kondisi augmentasi. Pembahasan meliputi hasil pelatihan dan evaluasi *EfficientNet-B0* dan *FastViT-T8*, analisis *robustness* terhadap variasi kondisi visual seperti *brightness*, *contrast*, *saturation*, *hue*, *affine*,

perspective, dan *blur*, serta perbandingan performa kedua model berdasarkan metrik evaluasi yang digunakan. Selain itu, bab ini juga membahas implementasi sistem berbasis web menggunakan Gradio sebagai media demonstrasi model yang dikembangkan.

BAB V – SIMPULAN DAN SARAN

Bab ini berisi simpulan yang diperoleh berdasarkan hasil penelitian serta saran untuk pengembangan penelitian selanjutnya. Simpulan mencerminkan pencapaian tujuan penelitian, sedangkan saran difokuskan pada pengembangan metode, penggunaan augmentasi campuran, pemanfaatan dataset dengan penyakit campuran, serta pengujian pada kondisi lapangan yang lebih beragam.

