

BAB 1. PENDAHULUAN

1.1 Latar Belakang

Padi merupakan komoditas pangan utama bagi lebih dari 3,5 miliar penduduk di seluruh dunia, dan di Indonesia perannya bersifat fundamental dalam menopang ketahanan pangan nasional. Data Badan Pusat Statistik (BPS) menunjukkan bahwa luas panen padi pada tahun 2022 mencapai 10,45 juta hektar dengan produksi gabah kering giling (GKG) sebesar 54,75 juta ton atau setara 31,54 juta ton beras, sementara proyeksi produksi beras pada periode Januari–April 2025 diperkirakan mencapai 13,95 juta ton angka tertinggi sejak 2019 (BPS, 2025). Skala produksi yang besar ini menggarisbawahi betapa pentingnya menjaga keberlangsungan dan produktivitas budidaya padi dari berbagai ancaman, termasuk serangan penyakit daun yang dapat menyebabkan kerugian hasil panen secara masif.

Besarnya skala produksi padi tersebut menuntut adanya sistem pengelolaan pertanian yang lebih modern dan responsif, khususnya dalam hal deteksi dini penyakit tanaman. Perkembangan kecerdasan buatan dan pengolahan citra digital dalam satu dekade terakhir telah membuka peluang besar bagi transformasi sistem deteksi penyakit tanaman. Dalam konteks pertanian modern, kemampuan mengidentifikasi penyakit secara otomatis, cepat, dan akurat dari citra daun tanaman menjadi kebutuhan yang semakin mendesak, khususnya untuk komoditas strategis seperti padi. Pendekatan berbasis citra digital menawarkan alternatif yang jauh lebih skalabel dan konsisten dibandingkan metode inspeksi visual manual yang selama ini menjadi andalan petani dan penyuluh pertanian. Metode manual terbukti rentan terhadap kesalahan manusia, membutuhkan tenaga ahli yang tidak selalu tersedia di lapangan, serta tidak mampu mengimbangi kecepatan penyebaran penyakit di lahan yang luas (Shoaib dkk., 2023).

Urgensi penerapan teknologi deteksi berbasis citra ini semakin diperkuat oleh kompleksitas dan keragaman penyakit daun yang mengancam produktivitas padi di lapangan. Di antara berbagai faktor penghambat produktivitas padi, penyakit daun menjadi salah satu yang paling merugikan. Empat penyakit daun yang paling umum dan berbahaya meliputi: Hawar Daun Bakteri (HDB) atau kresek yang disebabkan

oleh bakteri *Xanthomonas oryzae* pv. *oryzae* dengan potensi kehilangan hasil 15–80% (Hadi dkk., 2025); Bercak Coklat akibat jamur *Bipolaris oryzae* yang menyerang semua stadia pertumbuhan dan dapat menurunkan kualitas serta viabilitas benih (Aidoo & Asamoah, 2025); penyakit Tungro yang disebabkan oleh koinfeksi dua virus (Rice Tungro Spherical Virus dan Rice Tungro Bacilliform Virus) yang ditularkan wereng hijau dan mengakibatkan tanaman kerdil serta perubahan warna daun menjadi kuning kemerahan (Rosida dkk., 2024); serta penyakit Blas akibat jamur *Pyricularia oryzae* yang dapat menyebabkan kerugian hasil 50–90% bahkan gagal panen total pada serangan stadium generatif (Ayu Lestari dkk., 2021). Kemiripan visual gejala antarpenyakit, terutama pada stadia awal, menjadikan identifikasi manual sangat sulit dan tidak reliabel.

Identifikasi penyakit daun padi secara manual menghadapi sejumlah keterbatasan fundamental. Pendekatan ini mengandalkan pengamatan visual oleh petani atau penyuluh pertanian yang tidak selalu memiliki keahlian diagnostik memadai, sehingga rentan terhadap misdiagnosis yang berujung pada penanganan yang tidak tepat sasaran. Selain itu, metode manual bersifat tidak skalabel karena tidak mampu menjangkau lahan yang luas dalam waktu singkat, sementara kecepatan penyebaran penyakit sering kali melampaui kapasitas respons manusia. Kajian literatur menunjukkan bahwa metode inspeksi tradisional bersifat padat karya, memerlukan waktu lama, dan sangat rentan terhadap kesalahan di bawah kondisi lingkungan yang bervariasi (Jafar dkk., 2024). Kondisi ini mendorong kebutuhan mendesak akan sistem deteksi otomatis berbasis kecerdasan buatan yang mampu memberikan diagnosis yang cepat, konsisten, dan akurat.

Kemajuan pesat dalam bidang *Deep Learning*, khususnya arsitektur *Convolutional Neural Network* (CNN), telah membuka paradigma baru dalam klasifikasi citra tanaman. Berbeda dengan pendekatan machine learning tradisional yang memerlukan rekayasa fitur secara manual, CNN mampu mengekstraksi fitur visual yang kompleks mulai dari tepi, tekstur, hingga pola warna secara otomatis dari citra mentah (Alzubaidi dkk., 2021). Kemampuan ini menjadikan CNN sangat efektif untuk membedakan pola visual penyakit yang tampak serupa secara kasat mata. Lebih lanjut, teknik transfer learning memungkinkan pemanfaatan

pengetahuan yang telah dipelajari model dari dataset skala besar seperti ImageNet, sehingga model dapat bekerja dengan baik bahkan pada dataset pertanian yang relatif terbatas sekalipun (Sari, 2025). Kombinasi CNN dan transfer learning kini menjadi pendekatan dominan dalam penelitian deteksi penyakit tanaman berbasis citra digital.

Di antara berbagai arsitektur CNN yang tersedia, keluarga EfficientNet yang diperkenalkan oleh Tan & Le (2019) menonjol karena pendekatannya yang unik dalam penskalaan model secara komposit menyeimbangkan kedalaman jaringan, lebar jaringan, dan resolusi input secara proporsional. Pendekatan ini menghasilkan model yang tidak hanya akurat, tetapi juga efisien secara komputasi. EfficientNet-B0 dan EfficientNet-B1 sebagai varian terkecil dalam keluarga ini menawarkan trade-off yang menarik antara akurasi tinggi dan kompleksitas model yang rendah, menjadikannya kandidat ideal untuk aplikasi di lapangan yang memiliki keterbatasan sumber daya komputasi. Penelitian terbaru membuktikan bahwa EfficientNet-B0 mampu mencapai akurasi klasifikasi terbaik di antara arsitektur ringan dengan Top-1 accuracy 82,75% pada dataset CIFAR-100 dalam kondisi pengujian yang seragam (Fauzan dkk., 2026), sementara studi lain mengkonfirmasi bahwa EfficientNetB0 menawarkan trade-off terbaik antara akurasi dan kompleksitas komputasi dalam kondisi data terbatas (Karataş & Atabas, 2026).

Sejumlah penelitian terdahulu telah membuktikan efektivitas arsitektur EfficientNet dalam klasifikasi penyakit daun padi. Ahdi (2023) berhasil mencapai akurasi 98,93% menggunakan EfficientNet-B0 dengan strategi augmentasi data dan normalisasi lapisan pada empat kelas penyakit. (Nugroho, 2025) mengkonfirmasi bahwa EfficientNet-B0 hingga B2 yang dilatih dengan teknik transfer learning dan fine-tuning mampu mencapai akurasi 0,99 pada dataset lima kelas penyakit padi dan berhasil diimplementasikan pada perangkat mobile Android. Sebaliknya, penggunaan EfficientNet-B6 yang jauh lebih besar justru menghasilkan akurasi lebih rendah, yaitu 77,05% (Milano dkk., 2024), mengindikasikan bahwa model berukuran lebih besar tidak otomatis menghasilkan performa lebih baik tanpa strategi pelatihan yang tepat. Meskipun berbagai penelitian telah menguji varian EfficientNet secara individual, perbandingan langsung dan sistematis antara

EfficientNet-B0 dan EfficientNet-B1 dalam konteks klasifikasi penyakit daun padi menggunakan dataset yang sama, pipeline yang identik, serta analisis komprehensif terhadap keduanya masih jarang dilakukan.

Kesenjangan tersebut menjadi landasan utama penelitian ini. Penelitian ini mengusulkan perbandingan langsung antara EfficientNet-B0 dan EfficientNet-B1 dengan teknik transfer learning untuk klasifikasi penyakit daun padi berbasis citra digital, mencakup empat kelas penyakit utama Hawar Daun Bakteri, Bercak Coklat, Tungro, dan Blas serta kelas daun sehat. Pemilihan kedua varian ini didasarkan pada bukti empiris kemampuannya menghasilkan performa tinggi dengan kompleksitas model rendah, sekaligus ketersediaan bobot pralatih dari ImageNet yang memungkinkan generalisasi yang baik pada dataset pertanian. Dengan menganalisis secara komparatif akurasi, presisi, *recall*, F1-score, serta efisiensi komputasi keduanya, penelitian ini diharapkan dapat memberikan rekomendasi berbasis data mengenai arsitektur yang paling sesuai untuk sistem deteksi dini penyakit daun padi di lapangan, yang pada akhirnya berkontribusi pada peningkatan produktivitas padi dan penguatan ketahanan pangan nasional.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan, rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana membangun sistem klasifikasi penyakit daun padi berdasarkan citra digital menggunakan metode *deep learning*?
2. Bagaimana performa model *EfficientNet-B0* dan *EfficientNet-B1* dalam mengklasifikasikan empat kelas penyakit daun padi dan satu kelas sehat: *bacterial blight*, *brown spot*, *tungro*, *Blast*, dan *sehat*?

1.3 Tujuan

Penelitian ini memiliki tujuan sebagai berikut:

1. Merancang dan mengimplementasikan sistem klasifikasi penyakit daun padi berbasis citra digital menggunakan metode *deep learning*.
2. Menganalisis performa model *EfficientNet-B0* dan *EfficientNet-B1* dalam klasifikasi lima jenis penyakit daun padi.

1.4 Manfaat

Penelitian ini diharapkan bisa memberikan banyak manfaat, baik langsung maupun tidak langsung, untuk membantu meningkatkan hasil panen padi dan menjaga ketahanan pangan kita. Manfaat-manfaat ini bisa dilihat dari beberapa sisi:

1. Untuk Petani dan Petugas Pertanian:
 - a. Bisa Mendeteksi Penyakit Lebih Awal dan Akurat: Penelitian ini menciptakan alat berbasis teknologi kecerdasan buatan (*Deep Learning EfficientNet*) yang bisa mengenali jenis penyakit daun padi dengan cepat dan tepat hanya dari foto digital. Dengan kemampuan ini, petani bisa tahu ada masalah pada padinya lebih dini, sebelum penyakitnya menyebar luas dan menyebabkan kerugian besar.
 - b. Membantu Mengambil Keputusan yang Tepat: Diagnosa yang akurat akan mempermudah petani dan petugas pertanian untuk memutuskan langkah penanganan yang paling pas dan efektif. Misalnya, petani bisa memilih obat atau cara pengendalian lain yang benar-benar dibutuhkan. Ini akan mengurangi pemakaian bahan kimia berlebihan, menekan biaya, dan meminimalkan dampak buruk pada lingkungan.
2. Untuk Peneliti dan Kalangan Akademis:
 - a. Sumber Referensi dan Pengembangan Model Baru: Hasil penelitian ini akan menjadi referensi penting bagi para peneliti dan akademisi di bidang pertanian, ilmu komputer, dan kecerdasan buatan. Model *EfficientNet* yang kami pakai dan analisis dalam penelitian ini bisa menjadi dasar untuk pengembangan lebih lanjut, baik untuk mendeteksi penyakit tanaman lain maupun untuk mencoba arsitektur deep learning yang lebih maju.
 - b. Pedoman Metodologi: Cara kerja yang peneliti/penulis gunakan, mulai dari pengumpulan data, persiapan data, sampai pelatihan dan evaluasi model, bisa menjadi panduan bagi penelitian sejenis di masa mendatang.
3. Untuk Lembaga Pendidikan dan Penelitian:
 - a. Mendukung Inovasi di Bidang Pertanian: Penelitian ini sejalan dengan upaya pemerintah dan lembaga pendidikan untuk memajukan teknologi pertanian berbasis kecerdasan buatan.
 - b. Meningkatkan Kemampuan Riset: Adanya penelitian ini akan meningkatkan kapasitas riset di Politeknik Negeri Jember, membuka

peluang untuk kerja sama penelitian lebih lanjut dan pengembangan program studi yang relevan.

- c. Materi Belajar dan Praktikum: Data, kode, dan hasil analisis dari penelitian ini bisa dimanfaatkan sebagai bahan ajar dan praktikum bagi mahasiswa. Ini akan memberi mereka pengalaman langsung dalam menerapkan deep learning untuk menyelesaikan masalah nyata.
4. Untuk Pengembang Sistem dan Industri Teknologi:
 - a. Dasar untuk Pengembangan Aplikasi Masa Depan: Temuan dari penelitian ini bisa menjadi fondasi kuat untuk membuat aplikasi pendeteksi penyakit padi yang lebih canggih di masa depan. Ini termasuk kemungkinan aplikasi pada perangkat *mobile*, perangkat IoT (*Internet of Things*) untuk pemantauan di lapangan, atau integrasi dengan sistem informasi pertanian yang lebih besar.
 - b. Peluang Komersialisasi: Dengan hasil model yang terbukti bagus, ada kesempatan bagi pengembang sistem dan perusahaan teknologi untuk menjadikan solusi ini produk atau layanan yang bisa dipakai secara luas oleh petani dan pelaku agribisnis.
 - c. Mendorong Inovasi di Agritech: Keberhasilan sistem ini bisa memicu lahirnya ekosistem inovasi di bidang agritech (teknologi pertanian), yang pada gilirannya akan menarik investasi dan talenta untuk menciptakan solusi-solusi cerdas lainnya.

Penelitian ini diharapkan membawa dampak positif yang luas, tidak hanya di dunia akademis, tapi juga dalam praktik pertanian sehari-hari, serta turut berkontribusi pada ketahanan pangan dan peningkatan kesejahteraan petani di Indonesia.

1.5 Batasan Masalah

Berdasarkan cakupan penelitian yang telah ditetapkan, penelitian ini memiliki batasan sebagai berikut:

1. Arsitektur Model: Penelitian ini hanya menggunakan arsitektur *EfficientNet-B0* dan *EfficientNet-B1*. Berdasarkan kajian SOTA, varian *EfficientNet* yang lebih besar seperti *EfficientNet-B6* terbukti menghasilkan akurasi lebih rendah

(77,05%) dibandingkan varian yang lebih kecil (Milano dkk., 2024), sedangkan EfficientNet-B0 dan B1 dengan *fine-tuning* terbukti mampu mencapai akurasi hingga 99% pada dataset klasifikasi penyakit daun padi (Nugroho, 2025). Perbandingan langsung dan sistematis antara EfficientNet-B0 dan EfficientNet-B1 pada dataset dan *pipeline* yang identik masih jarang dilakukan, sehingga menjadi fokus utama penelitian ini.

2. Cakupan Kelas Penyakit: Penelitian ini hanya mengklasifikasikan lima kelas, yaitu *Bacterial Blight*, *Blast*, *Brown Spot*, *Tungro*, dan Sehat. Cakupan ini lebih komprehensif dibandingkan beberapa penelitian SOTA yang hanya menangani dua hingga tiga kelas, seperti Anggiratih dkk. (2021) yang membatasi pada dua kelas dengan akurasi 79,53%, sehingga kurang merepresentasikan kompleksitas kondisi lapangan. Penyakit lain di luar kelima kelas tersebut, maupun kombinasi infeksi ganda, tidak termasuk dalam cakupan penelitian ini.
3. Dataset dan Teknik Pelatihan: Penelitian ini menggunakan dataset sebanyak 6.932 citra daun padi dengan rasio pembagian 70:15:15 untuk pelatihan, validasi, dan pengujian. Pelatihan dilakukan dalam dua fase, yaitu fase *freezing* dan *fine-tuning* dengan bobot pralatih ImageNet, mengacu pada pendekatan yang terbukti efektif dalam SOTA (Nugroho, 2025; Ahdi, 2023). Penelitian ini tidak mencakup implementasi *deployment* pada perangkat *mobile* maupun pengujian kecepatan inferensi secara nyata, sebagaimana dilakukan Nugroho (2025) yang *men-deploy* model ke Android via TensorFlow Lite.
4. Metrik Evaluasi: Evaluasi performa model dibatasi pada metrik akurasi, presisi, *recall*, dan F1-Score makro, konsisten dengan standar yang digunakan dalam penelitian-penelitian SOTA (Satria & Putra, 2025; Dimara dkk., 2025; Suciani dkk., 2025). Analisis efisiensi komputasi seperti pengukuran *runtime* inferensi pada perangkat keras terbatas tidak termasuk dalam cakupan penelitian ini, meskipun hal tersebut diakui sebagai aspek penting untuk implementasi lapangan sebagaimana disoroti oleh Nugroho (2025).