

BAB 1

PENDAHULUAN

1.1 Latar Belakang Masalah

Deteksi dini penyakit tanaman berbasis citra digital merupakan salah satu penerapan *deep learning* yang berkembang pesat, khususnya dengan kemunculan arsitektur *Convolutional Neural Network* (CNN) modern yang mampu mengekstraksi fitur visual secara otomatis. Identifikasi penyakit dengan cara konvensional masih bergantung pada pengamatan visual oleh tenaga ahli di lapangan, yang cenderung subjektif, membutuhkan waktu lama, serta kurang efektif untuk diterapkan pada area pertanian berskala besar [1]. Meskipun model-model *state-of-the-art* seperti ConvNeXt menunjukkan performa tinggi dalam mengatasi permasalahan tersebut, kompleksitas arsitektur dan kebutuhan komputasinya sering kali menjadi kendala bagi implementasi pada sistem dengan sumber daya terbatas, sehingga diperlukan kajian mengenai *trade-off* antara performa dan efisiensi model [2].

Untuk mengevaluasi *trade-off* tersebut secara terukur, penelitian ini menggunakan studi kasus klasifikasi penyakit *powdery mildew* pada citra daun cherry (*Prunus avium*) yang bersumber dari *dataset* publik PlantVillage — salah satu *dataset benchmark* yang paling banyak digunakan dalam penelitian deteksi penyakit tanaman berbasis *deep learning* [3]. Kasus ini dipilih karena secara metodologis menghadirkan kondisi eksperimen yang terkontrol: *powdery mildew* memiliki gejala visual yang khas berupa bercak putih bertepung pada permukaan daun, dan tugas klasifikasinya bersifat biner (sehat vs. terinfeksi), sehingga perbedaan performa antararsitektur dapat diatribusikan secara lebih murni pada kapabilitas model, bukan pada kompleksitas data [4]. Penggunaan *dataset benchmark* ini juga memastikan kualitas dan reliabilitas data, mengingat PlantVillage telah menjadi rujukan standar yang terkurasi dalam berbagai penelitian klasifikasi penyakit tanaman berbasis *deep learning* [5][6]. Perlu dicatat bahwa pemilihan cherry sebagai objek studi kasus tidak dimaksudkan untuk merepresentasikan komoditas pertanian Indonesia secara spesifik, melainkan sebagai *test-bed* yang representatif untuk mengevaluasi kelayakan arsitektur CNN sederhana dibandingkan model *transfer learning* modern. Terlebih, *powdery mildew* merupakan salah satu penyakit tanaman terpenting yang menyerang

beragam komoditas hortikultura — termasuk stroberi, anggur, dan tanaman famili Cucurbitaceae yang turut dibudidayakan di Indonesia — sehingga metodologi yang diuji dalam penelitian ini diharapkan dapat digeneralisasi pada tugas klasifikasi penyakit tanaman lain yang relevan dengan konteks Indonesia.

Efektivitas CNN untuk klasifikasi penyakit tanaman telah dibuktikan sejak awal melalui penelitian Mohanty dkk. yang mengklasifikasikan 26 jenis penyakit pada 14 spesies tanaman menggunakan *dataset* PlantVillage, dan menjadi salah satu tonggak awal yang membuktikan efektivitas CNN untuk keperluan ini [3]. Setelah itu, berbagai jenis arsitektur CNN terus dikembangkan dan diterapkan pada tugas klasifikasi yang sejenis [2], termasuk penggunaan *transfer learning* yang terbukti meningkatkan performa klasifikasi walaupun jumlah data berlabel masih terbatas [6].

Di antara arsitektur CNN modern, ConvNeXt yang diperkenalkan oleh Liu dkk. (2022) dikembangkan dengan mengadopsi beberapa prinsip desain dari *Vision Transformer*, namun tetap mempertahankan karakteristik jaringan konvolusi, dan mampu menghasilkan performa yang kompetitif pada tugas klasifikasi citra skala besar [1]. Pada domain penyakit tanaman, ConvNeXt juga menunjukkan kemampuan yang baik dalam mengekstraksi fitur spasial tingkat tinggi dari citra daun sehingga mampu menghasilkan tingkat akurasi klasifikasi yang tinggi [7]. Oleh karena itu, ConvNeXt-Tiny dipilih dalam penelitian ini sebagai representasi arsitektur CNN modern berbasis *transfer learning* yang memiliki kemampuan ekstraksi fitur yang kuat.

Meskipun demikian, model *deep learning* modern pada umumnya memiliki arsitektur yang lebih kompleks, jumlah parameter yang lebih banyak, serta kebutuhan komputasi yang lebih tinggi. Beberapa penelitian menekankan bahwa model *state-of-the-art* sering kali memerlukan kemampuan pemrosesan yang tinggi sehingga kurang praktis apabila diimplementasikan pada sistem dengan sumber daya terbatas [8]. Kendala ini menjadi krusial karena sistem deteksi penyakit tanaman justru paling bermanfaat apabila dapat dijalankan langsung di lapangan, misalnya pada *smartphone* atau *edge device* yang lazim digunakan petani, yang sering beroperasi tanpa koneksi internet stabil serta memiliki keterbatasan memori dan daya komputasi [3]. Dalam kondisi tersebut, model dengan akurasi tertinggi belum tentu menjadi pilihan terbaik apabila kebutuhan komputasinya terlalu besar untuk diimplementasikan. Di sisi lain, kesalahan klasifikasi — khususnya *false negative* ketika daun terinfeksi diklasifikasikan sebagai sehat — berpotensi mempercepat penyebaran penyakit, sehingga efisiensi tidak dapat

dikejar dengan mengorbankan performa secara sembarangan. Justru karena kedua kebutuhan ini saling bertolak belakang, *trade-off* antara performa klasifikasi dan efisiensi komputasi perlu diukur secara sistematis agar pemilihan arsitektur dapat dilandaskan pada bukti kuantitatif, bukan asumsi bahwa model yang lebih kompleks selalu lebih unggul. Hal ini sekaligus menunjukkan perlunya kajian terhadap model yang lebih sederhana sebagai alternatif, khususnya ketika kebutuhan sistem tidak hanya berpaku pada akurasi, tetapi juga pada ukuran model, jumlah parameter, dan kebutuhan komputasi.

1.2 Rumusan Masalah

Berdasarkan uraian latar belakang tersebut, rumusan masalah pada penelitian ini dapat dirumuskan sebagai berikut:

1. Bagaimana performa model ConvNeXt-Tiny berbasis *feature extraction* dalam klasifikasi citra daun cherry sehat dan daun cherry yang terinfeksi *powdery mildew*?
2. Bagaimana performa model SimpleCNN yang dilatih dari awal (*from scratch*) dalam klasifikasi citra daun cherry sehat dan daun cherry yang terinfeksi *powdery mildew*?
3. Bagaimana *trade-off* antara performa klasifikasi dan efisiensi komputasi kedua model, dan apakah SimpleCNN masih layak dipertimbangkan sebagai alternatif sederhana terhadap ConvNeXt-Tiny?

1.3 Batasan Permasalahan

Guna menjaga agar penelitian tetap memiliki arah yang jelas dan memiliki lingkup yang jelas, ditetapkan beberapa batasan penelitian sebagai berikut:

1. Dataset yang digunakan adalah citra daun cherry dengan dua kelas, yaitu *healthy* sebanyak 854 gambar dan *powdery mildew* atau *disease* sebanyak 1052 gambar, sehingga total dataset berjumlah 1906 gambar. Dataset yang digunakan pada proses pelatihan dan evaluasi dibagi menjadi tiga subset, yaitu 1219 citra untuk data pelatihan, 266 citra untuk data validasi, dan 421 citra untuk data uji. Pembagian ini digunakan secara konsisten pada proses pelatihan, validasi, dan evaluasi model.

2. Penelitian ini dibatasi pada klasifikasi biner, yaitu membedakan daun cherry sehat dan daun cherry yang terinfeksi *powdery mildew*, sesuai dengan kategori yang tersedia pada *dataset* PlantVillage. Penyakit daun cherry lain — seperti *cherry leaf spot* dan *shot hole disease* — serta kemungkinan infeksi ganda (lebih dari satu penyakit pada satu daun) berada di luar ruang lingkup penelitian ini. Pembatasan ini dilakukan secara sengaja agar perbandingan antararsitektur dapat dievaluasi pada kondisi yang terkontrol, sehingga perbedaan performa yang teramati dapat diatribusikan pada kapabilitas model, bukan pada kompleksitas tugas klasifikasi.
3. Model yang dibandingkan dibatasi pada dua arsitektur, yaitu ConvNeXt-Tiny dengan bobot pra-latih ImageNet menggunakan strategi *feature extraction*, dan CNN sederhana kustom atau SimpleCNN yang dilatih sepenuhnya dari awal tanpa bobot pra-latih. Pada model ConvNeXt-Tiny, seluruh lapisan *backbone* dibekukan dan hanya bagian *classifier* yang dilatih ulang.
4. Kedua model menggunakan ukuran citra masukan sebesar 224×224 piksel
5. Pelatihan kedua model dilakukan selama 5 *epoch* menggunakan *framework* PyTorch dengan *batch size* 16 dan perangkat GPU CUDA apabila tersedia.
6. Proses augmentasi data hanya dilakukan pada data pelatihan, sedangkan data validasi dan data pengujian hanya melewati tahapan proses *resize*, konversi ke tensor, dan normalisasi. Augmentasi dilakukan secara *on-the-fly*, sehingga tidak menambah jumlah file citra secara permanen.
7. Analisis *trade-off* dilakukan berdasarkan performa klasifikasi dan beberapa indikator efisiensi komputasi. Kinerja klasifikasi diukur menggunakan metrik akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix*. Sementara itu, indikator efisiensi komputasi yang digunakan meliputi jumlah parameter, jumlah parameter yang dilatih, ukuran model, waktu pelatihan, waktu inferensi per citra, penggunaan memori, dan estimasi GFLOPs.
8. Pengukuran efisiensi komputasi dilakukan pada lingkungan eksperimen yang digunakan dalam penelitian ini. Oleh karena itu, hasil pengukuran waktu pelatihan, waktu inferensi, dan penggunaan memori dapat dipengaruhi oleh spesifikasi perangkat keras, ketersediaan GPU, serta kondisi *runtime* pada saat eksperimen dilakukan.

9. Penelitian ini tidak mencakup implementasi sistem secara langsung pada perangkat *edge*, perangkat mobile, atau sistem deteksi penyakit tanaman secara *real-time*. Penelitian juga tidak mengukur konsumsi daya perangkat maupun biaya perangkat keras yang dibutuhkan untuk menjalankan masing-masing model.

1.4 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah disusun, tujuan penelitian ini adalah sebagai berikut:

1. Mengukur performa klasifikasi dan efisiensi komputasi model ConvNeXt-Tiny dalam klasifikasi citra daun cherry sehat dan daun cherry yang terinfeksi *powdery mildew*, dengan performa klasifikasi dinilai berdasarkan akurasi, presisi, *recall*, dan *F1-score*, serta efisiensi komputasi dinilai berdasarkan jumlah parameter, ukuran model, waktu pelatihan, waktu inferensi, penggunaan memori, dan estimasi GFLOPs.
2. Mengukur performa klasifikasi dan efisiensi komputasi model SimpleCNN yang dilatih dari awal (*from scratch*) pada tugas klasifikasi yang sama, menggunakan metrik performa dan indikator efisiensi yang identik dengan poin pertama.
3. Menentukan kelayakan SimpleCNN sebagai alternatif ConvNeXt-Tiny berdasarkan analisis *trade-off* antara performa klasifikasi dan efisiensi komputasi yang diperoleh dari kedua pengukuran tersebut.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan beberapa manfaat sebagai berikut:

1. **Bagi ilmu pengetahuan:** Menambah referensi empiris terkait perbandingan ConvNeXt-Tiny berbasis *feature extraction* dan CNN sederhana dalam domain klasifikasi penyakit daun cherry, serta memberikan gambaran mengenai hubungan antara kompleksitas arsitektur dan performa model.
2. **Bagi praktisi pertanian:** Memberikan gambaran mengenai kelayakan pendekatan deep learning berbasis CNN sederhana maupun transfer learning

untuk sistem deteksi penyakit tanaman secara otomatis, yang metodologinya berpotensi diadaptasi pada komoditas pertanian lain yang relevan dengan konteks Indonesia.

3. **Bagi peneliti selanjutnya:** Memberikan *baseline* yang dapat dijadikan landasan untuk pengembangan penelitian lanjutan misalnya dengan menerapkan *fine-tuning* penuh, arsitektur lain seperti MobileNet untuk perangkat *edge* [9], atau pendekatan *ensemble* [10].
4. **Bagi pengembang sistem:** Memberikan panduan praktis dalam menentukan arsitektur berdasarkan ketersediaan data serta sumber daya komputasi yang tersedia.


1.6 Sistematika Penulisan

Susunan penulisan laporan dalam penelitian ini adalah sebagai berikut:

- **Bab 1 PENDAHULUAN**
Bab ini membahas latar belakang pemilihan topik, rumusan masalah, batasan permasalahan, tujuan penelitian, manfaat penelitian, serta sistematika penulisan laporan.
- **Bab 2 LANDASAN TEORI**
Bab ini menguraikan landasan teori yang menjadi dasar penelitian, meliputi penyakit *powdery mildew* pada cherry, konsep CNN, arsitektur ConvNeXt-Tiny, strategi *feature extraction*, teknik augmentasi data, serta tinjauan pustaka terkait.
- **Bab 3 METODOLOGI PENELITIAN**
Bab ini membahas metodologi penelitian, meliputi proses pengumpulan dan persiapan dataset, detail arsitektur kedua model, strategi pelatihan, dan metrik evaluasi yang digunakan.
- **Bab 4 HASIL DAN DISKUSI**
Bab ini menyajikan hasil eksperimen beserta analisis perbandingan performa antara model ConvNeXt-Tiny dan SimpleCNN, disertai pembahasan terhadap temuan yang diperoleh.

- Bab 5 KESIMPULAN DAN SARAN

Bab ini menyajikan simpulan dari seluruh penelitian berdasarkan hasil dan analisis yang telah dilakukan, serta saran untuk penelitian selanjutnya.



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA