

BAB I

PENDAHULUAN

1.1 Latar Belakang

Bayam adalah salah satu jenis sayuran hijau yang sangat populer di Asia, termasuk Indonesia [1]. Berdasarkan Badan Pusat Statistik (BPS), bayam berada di urutan kedua menjadi sayur yang paling banyak dikonsumsi di Indonesia pada tahun 2024, dengan jumlah rata-rata konsumsi sebanyak 0,061 Kg [2]. Pada pengabdian masyarakat di kelompok tani “Malawo Sejahtera” di Kelurahan Jamaimo, Distrik Mariat, Kabupaten Sorong, melakukan kegiatan sosialisasi dan pendampingan teknik penyemaian benih dan budidaya bayam dikarenakan mudah ditanam dan memiliki nilai ekonomi yang tinggi [3]. Akan tetapi, serangan penyakit dan hama pada daun bayam seperti jamur dan serangga penghisap dapat menurunkan kualitas serta kuantitas hasil panen, bahkan berpotensi menyebabkan gagal panen apabila tidak ditangani secara tepat waktu [4]. Identifikasi penyakit daun bayam umumnya masih dilakukan secara manual mengandalkan pengamatan visual gejala di lapangan yang dilakukan secara berkala oleh petani atau pengelola lahan [5].

Perkembangan teknologi *computer vision* dan *deep learning*, khususnya *Convolutional Neural Network* (CNN), telah membuka peluang besar dalam otomatisasi deteksi penyakit tanaman berbasis citra daun. Berbagai penelitian menunjukkan bahwa CNN mampu mengklasifikasikan penyakit daun dengan akurasi tinggi pada beragam tanaman, seperti anggur, ubi jalar, padi, daun tomat, dan tanaman lainnya [6][7][8][9]. Berbagai penelitian terkini menunjukkan bahwa CNN dan turunannya mampu mengklasifikasikan penyakit daun dengan tingkat akurasi yang beragam pada berbagai jenis tanaman. CNN juga terbukti dapat mengidentifikasi jenis tanaman berdasarkan gambar daun berdasarkan variasi 50 *epoch* dan variasi pembagian data 90:10 dengan hasil akurasi terbaik sebesar 93% [56]. Adapun model *hibrida* Inception-Xception diusulkan untuk klasifikasi penyakit tanaman dengan hasil model dapat mencapai akurasi 98,64% hingga 100% untuk berbagai jenis penyakit daun [10]. Proses *fine tuning* yang diterapkan pada

model EfficientNet-B0 untuk klasifikasi penyakit daun apel juga mencapai akurasi lebih dari 99,6% dengan konsumsi memori dan FLOPs yang tetap rendah, sehingga cocok untuk lingkungan sumber daya terbatas [11]. MobileNetV3Large yang dimodifikasi mencapai performa terbaik dibandingkan dengan model *baseline* seperti EfficientNetB1 dan CNN custom yang dibuat sebelumnya untuk mendeteksi berbagai jenis penyakit pada tanaman kacang, kembang kol, nangka, bayam, dan mangga. Secara spesifik, model yang dikembangkan mencapai akurasi pengujian sebesar 99,37%, lebih tinggi dari EfficientNetB1 (98,3%), MobileNetV3 baseline (98,97%), dan CNN kustom (95,51%) [12]. Studi lain pada penyakit daun apel, tomat, dan anggur menggunakan *Convolutional Neural Network* ringan dengan fusi fitur tekstur yang menghasilkan nilai akurasi uji 96,5-98,8% [13]. Dari beberapa penelitian yang telah ada, menjadi pendukung bahwa *Convolutional Neural Network* dinilai efektif untuk deteksi otomatis penyakit daun tanaman.

Berkembangnya model arsitektur *Convolutional Neural Network* (CNN) yang efisien, ringan, dan tingkat akurat baik menjadi hal yang sangat penting dikarenakan dapat menjadi kunci dalam penerapan AI (*Artificial Intelligence*) yang praktis mudah diterapkan di sumber daya perangkat yang terbatas dengan hasil akurasi yang baik [14]. Beberapa penelitian terkini mengevaluasi dan mengembangkan model ringan seperti MobileNetV3, ShuffleNetV2, GhostNet, EfficientNetV2, dan arsitektur CNN kustom untuk klasifikasi penyakit daun tomat, daun gandum, dan tanaman lainnya dengan akurasi 95% hingga 98,65% serta ukuran parameter yang relatif kecil sehingga layak dipindahkan ke perangkat *mobile* ataupun diterapkan di *website* [15][16]. Adapun penelitian yang memperkenalkan arsitektur *Convolutional Neural Network* baru yaitu Mob-Res, menggabungkan MobileNetV2 dan *residual learning* dalam satu model ringan yang hanya memiliki 3,51 juta parameter dengan hasil akurasi yang dilaporkan yaitu 97,73% pada dataset *Plant Disease Expert* dan 99,47% pada *PlantVillage* [17]. Penelitian-penelitian tersebut menunjukkan bahwa pemodelan yang efisien dan hemat komputasi menjadi kunci implementasi sistem deteksi penyakit di perangkat yang mempunyai sumber daya komputasi yang terbatas.

Sistem deteksi penyakit daun tanaman berbasis *deep learning* terus berkembang ke arah model yang semakin akurat sekaligus ringan untuk bisa dijalankan di

perangkat dengan sumber daya terbatas. Salah satu arsitektur yang digunakan pada penelitian ini adalah SqueezeNet yang merupakan arsitektur CNN ringan yang dirancang untuk mempertahankan akurasi tinggi dengan jumlah parameter yang 50 kali lipat jauh lebih sedikit dibandingkan model besar seperti AlexNet dan memiliki jumlah parameter sekitar 1,2 juta parameter [55][24]. Pada penelitian tiga tahun terakhir, banyak berfokus pada pengembangan model CNN baru, integrasi dengan modul lain, atau kombinasi dengan transformer, serta implementasi di aplikasi *mobile* [18][19]. SqueezeNet sendiri terbukti kompetitif pada klasifikasi penyakit daun jagung, SqueezeNet mencapai akurasi 97% dan mengungguli VGG16, ResNet34, dan ResNet50 dengan *error* yang lebih rendah [20]. Dan pada diagnosis penyakit tebu, SqueezeNet dijadikan salah satu *baseline* ringan yang dikalahkan model ShuffleNet khusus yang dioptimalkan untuk perangkat rendah sumber daya [21].

Di sisi lain, berbagai studi lain menunjukkan bahwa *fine-tuning hyperparameter* seperti *learning rate*, *optimizer*, *batch size*, jumlah *epoch*, *scheduler*, *dropout*, dan konfigurasi *layer* dapat meningkatkan akurasi model secara signifikan tanpa harus mengubah arsitektur dasar [22][18]. Pada penelitian I. Cardoza, dkk. [46] melakukan eksplorasi terhadap kombinasi nilai *hyperparameter* utama CNN (*optimizer*, *learning rate*, *batch size*, *epochs*) menggunakan AlexNet dan InceptionV3 untuk klasifikasi senjata api. Sedangkan B.D. Perez-Perez, dkk [47] mengidentifikasi *hyperparameter* CNN yang paling berpengaruh untuk meningkatkan akurasi dan efisiensi pemrosesan dalam klasifikasi kematangan kurma Medjool menggunakan VGG-16, VGG-19, ResNet-50, ResNet-101, ResNet-152, AlexNet, InceptionV3, dan CNN *from scratch*. CNN sangat bergantung pada pengaturan *hyperparameter* seperti jumlah *epoch*, *batch size*, *optimizer*, *learning rate*, dan arsitektur jaringan. Pengaturan yang kurang tepat dapat menyebabkan model *underfitting*, *overfitting*, atau waktu pelatihan yang sangat lama tanpa peningkatan akurasi yang berarti [47]. Adapun penelitian oleh S. Jagdev, dkk. [25] untuk mendeteksi penyakit pada daun tanaman tomat yang menggunakan arsitektur SqueezeNet dengan mengatur *hyperparameter* pada *learning rate* dan menggunakan *optimizer* SGD with Momentum (SGDM), Adam, dan RMSProp. Hasil penelitian tersebut menunjukkan bahwa kombinasi Adam

optimizer dan *learning rate* 0.0004 menunjukkan performa terbaik dalam hal akurasi yaitu 99,91% selama pengujian dan 99,86% selama pelatihan untuk klasifikasi kelas TMV (*Tomato Mosaic Virus*), dan nilai F1-Score sebesar 99,42% dalam pengujian dan 99,38% dalam pelatihan pada kelas TYLCV (*Tomato Yellow Leaf Curl Virus*) [25].

Maka dari itu, penelitian ini akan mengevaluasi pengaruh kombinasi *hyperparameter* pada *learning rate* dan *optimizer* menggunakan arsitektur SqueezeNet untuk deteksi penyakit daun bayam. Jenis *optimizer* yang akan diterapkan pada penelitian ini adalah Nadam, Adam, dan Adamax dengan penetapan nilai *learning rate* tertentu. Dari penelitian ini, diharapkan dapat memberikan kontribusi nyata dalam mengidentifikasi pengaruh pengaturan *hyperparameter* yang optimal pada arsitektur, dengan membuktikan apakah *optimizer* Adam memberikan hasil yang optimal seperti penelitian sebelumnya jika digunakan SqueezeNet untuk mendeteksi penyakit daun bayam. Sehingga diharapkan juga penelitian ini dapat menjadi referensi bagi penelitian selanjutnya dalam pengembangan sistem klasifikasi penyakit tanaman yang lebih akurat dan efisien.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, penelitian ini merumuskan beberapa pertanyaan penelitian sebagai berikut:

- a. Bagaimana kinerja arsitektur SqueezeNet dalam pengaruh variasi *hyperparameter* (*learning rate* dan *optimizer*) terhadap nilai *accuracy*, *precision*, *recall*, dan *F1-Score* untuk deteksi penyakit daun bayam?
- b. Pengaturan *hyperparameter* mana yang paling optimal dan menghasilkan nilai prediksi yang baik untuk deteksi penyakit daun bayam?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah ditetapkan, penelitian ini dirancang dengan tujuan yang jelas untuk memberikan kontribusi nyata baik secara ilmiah maupun praktis dalam bidang deteksi penyakit tanaman berbasis *deep learning*. Adapun tujuan dari penelitian ini adalah sebagai berikut:

- a. Mengetahui kinerja arsitektur SqueezeNet dalam pengaruh variasi hyperparameter (*learning rate* dan *optimizer*) terhadap nilai *accuracy*, *precision*, *recall*, dan *F1-Score* untuk deteksi penyakit daun bayam.
- b. Menentukan konfigurasi *hyperparameter* SqueezeNet yang menghasilkan performa optimal atau terbaik untuk deteksi penyakit daun bayam.

1.4 Batasan Masalah

Agar penelitian ini dapat dilaksanakan secara terarah, maka perlu ditetapkan batasan-batasan penelitian yang jelas. Adapun batasan masalah dalam penelitian ini adalah sebagai berikut:

- a. Dataset yang digunakan berupa data gambar daun bayam kondisi normal dan terserang penyakit atau hama.
- b. Dataset gambar diambil dari satu sumber referensi yang berasal dari Data Mendeley, serta diambil dari lapangan secara langsung.
- c. Dataset terdiri dari satu kategori daun bayam sehat (*healthy*) dan empat kategori penyakit daun bayam (*anthracnose*, *bacterial spot*, *downy mildew*, dan *pest damage*).
- d. Arsitektur yang digunakan hanya SqueezeNet, tanpa membandingkan arsitektur lain secara langsung.
- e. Penelitian ini berfokus pada eksperimen *hyperparameter*, *learning rate*, serta *optimizer* Adam, Adamax, dan Nadam, dengan tujuan menganalisis performa model tanpa melibatkan pengembangan aplikasi maupun tahap *deployment*.
- f. Evaluasi kinerja hanya menggunakan metrik *accuracy*, *precision*, *F1-Score* dan *recall* berbasis *confusion matrix*.

1.5 Manfaat Penelitian

Penelitian ini diharapkan tidak hanya memberikan kontribusi dalam ranah akademik, tetapi juga memberikan dampak positif secara praktis bagi para pemangku kepentingan di bidang pertanian, khususnya dalam upaya peningkatan produktivitas dan ketahanan pangan. Adapun manfaat yang diharapkan dari penelitian ini adalah sebagai berikut:

1.5.1 Manfaat Akademis

Berikut manfaat akademis pada penelitian ini diantaranya sebagai berikut:

- a. Menambah kajian penerapan *deep learning* menggunakan arsitektur SqueezeNet pada klasifikasi citra penyakit daun bayam

Penelitian ini memberikan kontribusi literatur yang spesifik mengenai penerapan arsitektur SqueezeNet khususnya pada klasifikasi penyakit daun bayam. Mengingat sebagian besar penelitian sebelumnya lebih banyak mengkaji komoditas lain seperti tomat, jagung, pisang, dan kopi, maka penelitian ini mengisi kekosongan (*research gap*) yang selama ini belum banyak dibahas oleh peneliti, sehingga memperkaya literatur penelitian di bidang *computer vision* berbasis pertanian.

- a. Memberi referensi konfigurasi *hyperparameter* yang efektif pada arsitektur SqueezeNet

Penelitian ini memperluas kajian eksperimen terhadap arsitektur SqueezeNet yang mencakup kombinasi *optimizer* Adam, Adamax, dan Nadam dengan variasi *learning rate*, sehingga dapat dijadikan acuan ilmiah yang lebih komprehensif bagi peneliti selanjutnya.

- b. Mendorong penerapan model ringan (*lightweight CNN*) dalam penelitian pertanian.

Penggunaan arsitektur SqueezeNet yang tergolong ringan dalam penelitian ini turut mendorong berkembangnya kajian model *Convolutional Neural Network* yang efisien dari segi jumlah parameter dan kebutuhan komputasi, khususnya dalam konteks penelitian pertanian. Hal ini menjadi kontribusi akademis yang relevan mengingat semakin berkembangnya kebutuhan model *deep learning* yang dapat diterapkan pada perangkat dengan sumber daya terbatas, seperti *smartphone* atau perangkat IoT di lapangan, sehingga penelitian ini dapat menjadi rujukan bagi pengembangan model klasifikasi penyakit tanaman lain yang mengutamakan efisiensi tanpa mengorbankan akurasi secara signifikan.

1.5.2 Manfaat Sosial

Selain manfaat akademis, penelitian ini diharapkan memberi kontribusi untuk masyarakat terkhususnya untuk para petani, diantaranya sebagai berikut:

- a. Membantu petani mendeteksi penyakit lebih cepat dan akurat menggunakan teknologi *Artificial Intelligence* di sektor pertanian

Dengan adanya sistem deteksi berbasis SqueezeNet yang ringan dan akurat, petani berpeluang mendapatkan alat bantu diagnosis yang cepat, objektif, dan mudah digunakan, bahkan dari perangkat *mobile* sekalipun, tanpa memerlukan keahlian teknis khusus.

- b. Membantu mengurangi resiko gagal panen dan kerugian ekonomi petani

Deteksi penyakit yang terlambat merupakan salah satu penyebab utama penurunan hasil panen dan kerugian ekonomi bagi petani bayam. Dengan sistem deteksi dini yang lebih akurat, petani dapat segera mengambil tindakan pengendalian yang tepat sebelum penyakit menyebar lebih luas. Hal ini secara langsung dapat mengurangi kerugian ekonomi yang dialami petani, sekaligus menjaga stabilitas pendapatan mereka.


- c. Mendukung ketahanan pangan nasional

Bayam merupakan salah satu sumber gizi penting yang dikonsumsi oleh jutaan masyarakat Indonesia. Dengan sistem pertanian yang lebih sehat dan produktif melalui deteksi penyakit yang efektif, penelitian ini berkontribusi dalam menjaga ketersediaan dan kestabilan pasokan sayuran bergizi bagi masyarakat luas, hingga akhirnya mendukung ketahanan pangan nasional secara berkelanjutan.

1.6 Kerangka Pemikiran

Untuk memperoleh pemahaman secara menyeluruh mengenai arah penelitian ini, penyusunan kerangka pemikiran digunakan untuk menggambarkan hubungan antara setiap komponen penelitian secara terstruktur. Kerangka pemikiran ini diawali dari identifikasi masalah, yaitu proses deteksi penyakit daun bayam yang masih dilakukan secara manual, serta kebutuhan model yang ringan. Kemudian dihubungkan dengan solusi berbasis teknologi *deep learning* menggunakan arsitektur SqueezeNet, hingga akhir yaitu evaluasi model yang diharapkan mampu

memberikan kontribusi nyata bagi sektor pertanian. Adapun gambaran kerangka pemikiran penelitian ini disajikan sebagai berikut:



Gambar 1. 1 Kerangka Pemikiran

1.7 Sistematika Penulisan

Untuk memberikan gambaran yang jelas dan menyeluruh mengenai alur penelitian ini, berikut diuraikan sistematika penulisan yang digunakan dalam penyusunan laporan tugas akhir ini.

BAB 1 PENDAHULUAN

Bab ini menguraikan latar belakang penelitian yang menjelaskan topik penelitian yang diangkat. Selanjutnya, bab ini merumuskan masalah penelitian, menetapkan batasan penelitian agar kajian tetap terarah dan terukur, serta menjabarkan tujuan yang ingin dicapai. Bab ini juga memuat manfaat penelitian, baik dari sisi akademis maupun sosial, kerangka pemikiran yang menggambarkan alur logis penelitian secara visual, serta sistematika penulisan yang menjadi panduan pembaca dalam memahami keseluruhan laporan.

BAB 2 TINJAUAN PUSTAKA

Bab ini menyajikan kajian literatur dan landasan teori yang menjadi pijakan ilmiah penelitian ini. Bagian pertama membahas hasil penelitian terdahulu yang diperoleh melalui penelusuran sistematis terhadap artikel-artikel ilmiah. Bagian kedua menguraikan dasar teori yang mencakup konsep-konsep yang mendukung penelitian ini.

BAB 3 METODOLOGI PENELITIAN

Bab ini menjelaskan secara terperinci seluruh prosedur dan tahapan yang dilakukan dalam penelitian ini. Metodologi yang digunakan mengikuti kerangka CRISP-DM (*Cross-Industry Standard Process for Data Mining*), yang mencakup lima tahapan utama yang diantaranya *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modelling*, dan *Evaluation*.

BAB 4 HASIL DAN PEMBAHASAN

Bab ini menyajikan seluruh hasil eksperimen yang telah dirancang pada bab sebelumnya. Pada bab ini, hasil pelatihan dan pengujian dari 9 skenario eksperimen disajikan secara komparatif, mulai dari nilai *accuracy*, *precision*, *recall*, hingga *F1-Score* yang diperoleh masing-masing kombinasi *hyperparameter*. Pembahasan

difokuskan pada analisis pengaruh variasi *learning rate* dan pemilihan *optimizer* terhadap performa klasifikasi penyakit daun bayam, termasuk identifikasi konfigurasi *hyperparameter* yang menghasilkan performa terbaik.

BAB 5 KESIMPULAN

Bab ini menyajikan kesimpulan yang merangkum jawaban atas rumusan masalah penelitian berdasarkan hasil eksperimen yang telah dipaparkan pada bab sebelumnya, mencakup evaluasi kinerja arsitektur SqueezeNet terhadap variasi *hyperparameter* serta penentuan kombinasi *learning rate* dan *optimizer* yang paling optimal. Selain itu, bab ini juga memuat saran bagi penelitian selanjutnya sebagai bahan pertimbangan untuk pengembangan dan penyempurnaan penelitian di masa mendatang.

