

BAB 1

PENDAHULUAN

1.1 Latar Belakang


Pepaya (*Carica papaya L.*) merupakan salah satu komoditas hortikultura strategis di Indonesia. Dengan produksi mencapai 1.089.578 ton kurun waktu 1 tahun (Irfayanti dkk., 2022) menjadikan pepaya memiliki peran penting dalam perekonomian nasional. Namun, budidaya pepaya sering dihadapkan pada permasalahan berupa serangan berbagai penyakit, yang secara signifikan dapat mengancam keberlanjutan produksi serta kualitas hasilnya.

Salah satu penyakit utama yang menjadi ancaman bagi budidaya pepaya adalah *Papaya Ringspot Virus* (PRSV) dan *Begomovirus*. *Papaya Ringspot Virus* (PRSV) menyebabkan mosaik pada daun, klorosis pada lamina daun, dan mosaik bergaris seperti berminyak pada tangkai daun (Hidayat dkk., 2022). Sementara itu, infeksi *Begomovirus* yang menyebabkan gejala daun menguning dan mengeriting yang secara langsung menghambat pertumbuhan dan produktivitas tanaman (Pangesti dkk., 2022). Penyakit tersebut tidak hanya merusak daun, tetapi juga menyebabkan penurunan hasil dan kualitas buah pepaya (Helina dkk., 2024). Selain itu, identifikasi penyakit pada pepaya sering kali tidak mudah. Gejala pada daun sering kali mirip antar jenis penyakit atau tidak jelas di tahap awal infeksi, membuat pengamatan visual manual kurang efektif. Untuk mengatasi ini, diperlukan metode klasifikasi penyakit pepaya berbasis citra daun yang cepat dan akurat demi pengelolaan yang lebih optimal.

Teknologi *Artificial Intelligence* (AI) berkembang pesat dalam dekade terakhir, memungkinkan sistem meniru kemampuan kognitif manusia seperti belajar, memecahkan masalah dan mengambil keputusan dari data (Jai Chaudhary dkk., 2024). Salah satu sub bidang utamanya adalah *Machine Learning* (ML), di mana sistem belajar dari data untuk mencari pola dan membuat prediksi berdasarkan data tanpa diprogram secara eksplisit (Ongsulee, 2017). Sub bidang ML yang paling menonjol dan menunjukkan performa luar biasa adalah *Deep Learning* (DL). *Deep Learning* memanfaatkan jaringan syaraf tiruan dengan struktur mendalam (banyak lapisan) untuk secara otomatis

mempelajari representasi fitur langsung dari data mentah, tanpa perlu melakukan rekayasa fitur (*feature engineering*) secara manual (Goodfellow dkk., 2023). Salah satu algoritma *deep learning* yang paling populer dan efektif untuk pengolahan citra adalah *Convolutional Neural Network* (CNN).

CNN adalah salah satu algoritma *Deep Learning* yang digunakan untuk memproses data dua dimensi seperti citra. Berbeda dengan metode *machine learning* tradisional yang memerlukan ekstraksi fitur manual, CNN secara otomatis mengekstraksi fitur melalui operasi pada lapisan konvolusi dan *pooling*, yang kemudian diproses oleh lapisan *fully connected*. Hal ini menyebabkan model untuk mempelajari fitur-fitur yang lebih abstrak dan halus yang ada dalam citra, dan mengakibatkan peningkatan performa dan akurasi yang lebih baik. Keandalan CNN dalam mengklasifikasikan citra mencapai kinerja *state-of-the-art* dan menjadikan CNN populer dalam hal identifikasi citra.



Gambar 1.1 Ilustrasi Perbedaan *Machine Learning* dan *Deep Learning* (Sumber: Asher dkk., 2021)

Beberapa penelitian sebelumnya menggunakan model CNN individu untuk klasifikasi penyakit daun pepaya. Sebagai contoh, penelitian oleh (Nasution dkk., 2025) menggunakan arsitektur ResNet152v2 dengan tiga kelas target (*healthy*, *ringspot*, dan *curl leaf*), dan mendapatkan hasil akurasi 87%, *precision* 88%, *recall* 87%, serta *f1-score* 86%. Meskipun cukup baik, pendekatan ini memiliki keterbatasan dalam menangkap seluruh variasi fitur citra, terutama bentuk, tekstur, dan warna karena bias terhadap pola tertentu. Bias dalam bidang *machine learning* merujuk pada adanya perbedaan prediksi yang diharapkan dan targetnya. Model yang memiliki bias tinggi tidak dapat menyesuaikan

(*fitting*) data pelatihan yang baik, mengakibatkan kinerja yang buruk di dalam dan di luar sampel (*underfitting*) (Kyriakides & Margaritis, 2019). Bias yang tinggi dapat mengakibatkan misklasifikasi, seperti terlihat pada penelitian (Nasution dkk., 2025) memiliki nilai *recall* yang rendah (67%) pada kelas *healthy*, yang menunjukkan adanya aktual citra *healthy* yang diprediksi memiliki penyakit. Sementara itu, varians merujuk pada *error* yang timbul akibat sensitivitas model terhadap variasi data latih, sehingga performa dapat berfluktuasi secara signifikan ketika diuji pada *dataset* yang berbeda (*overfitting*) (Kyriakides & Margaritis, 2019).

Setiap arsitektur CNN memiliki karakteristik unik, seperti VGG16 mampu menangkap pola visual secara bertahap melalui struktur 16 lapisan dan filter konvolusi 3×3 (Simonyan & Zisserman, 2015), ResNet dengan *residual connection* efektif mempertahankan informasi fitur (He dkk., 2015), dan MobileNetV2 efisien berkat *depthwise separable convolution* (Sandler dkk., 2019). Keberagaman arsitektur ini sangat berarti karena memungkinkan model melihat citra dari sudut pandang yang berbeda, sehingga mengurangi bias dan varians jika digabungkan. *Ensemble learning* terbukti efektif dalam mengurangi bias dan varians dengan menyatukan kekuatan dan menutup kelemahan masing-masing model (Ganaie dkk., 2022).

Penggunaan *ensemble learning* mampu mengatasi kelemahan model tunggal dengan menggabungkan prediksi beberapa model untuk meningkatkan akurasi dan kemampuan generalisasi, yaitu model yang telah dilatih tetap memberikan prediksi yang akurat dan stabil pada data baru yang belum pernah dilihat saat *training* (Ganaie dkk., 2022). Hal ini terbukti pada penelitian oleh Hridoy & Tuli, (2021) yang menggabungkan model EfficientNet B5, EfficientNet B6, dan EfficientNet B7 menunjukkan peningkatan akurasi sekitar 1,61% dibandingkan model individual pada klasifikasi penyakit pepaya.

Hingga saat ini, belum ada penelitian yang secara khusus menggabungkan arsitektur VGG16, ResNet-34, dan MobileNetV2 menggunakan *soft voting* dalam mengklasifikasikan citra penyakit daun pepaya. Penelitian ini dilakukan untuk mengisi celah tersebut dengan menerapkan metode *soft voting* dengan

tujuan meningkatkan akurasi dan kemampuan generalisasi dibandingkan dengan model individu.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, terdapat beberapa rumusan masalah pada penelitian ini, di antaranya:

1. Berapa hasil evaluasi dengan metrik *accuracy*, *precision*, *recall* dan *f1-score* pada setiap arsitektur CNN ResNet-34, VGG16, dan MobileNetV2 sebelum dan setelah digabungkan dengan *soft voting*?
2. Apakah penggabungan model CNN VGG16, ResNet-34 dan MobileNetV2 dengan metode *soft voting* memberikan peningkatan performa prediksi dibandingkan model individu pada penelitian ini maupun penelitian sebelumnya (Nasution dkk.,2025) jika ditinjau dari metrik evaluasi *accuracy*, *precision*, *recall* dan *f1-score*?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah tersebut, maka tujuan penelitian ini adalah sebagai berikut:

1. Mengevaluasi performa masing-masing arsitektur CNN (ResNet-34, VGG16, dan MobileNetV2) secara individu maupun setelah digabungkan (*ensemble*) menggunakan metode *soft voting*, dengan menggunakan metrik evaluasi *accuracy*, *precision*, *recall*, dan *f1-score*.
2. Menguji pengaruh penggabungan (*ensemble*) model CNN dengan metode *soft voting* terhadap peningkatan performa prediksi dibandingkan model CNN individu terhadap klasifikasi citra penyakit daun pepaya.

1.4 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Mengetahui hasil evaluasi dengan metrik *accuracy*, *precision*, *recall* dan *f1-score* pada setiap arsitektur CNN ResNet-34, VGG16, dan MobileNetV2.

2. Mengetahui perbandingan hasil prediksi arsitektur CNN individual ResNet-34, VGG16, dan MobileNetV2 terhadap metode penggabungan dengan *soft voting* berdasarkan metrik *accuracy*, *precision*, *recall* dan *f1-score*.
3. Sebagai pedoman dalam *deployment* model ML berbasis web menggunakan *library* Gradio.

1.5 Batasan Penelitian

Adapun batasan masalah pada penelitian ini adalah:

1. *Dataset* dibagi menjadi 4 kelas, yaitu kelas *healthy leaf*, *ringspot leaf*, *yellow leaf* dan kelas *others*. Kelas tersebut merupakan kelas di dalam distribusi, sedangkan kelas *others* merupakan kelas di luar distribusi.
2. Penelitian ini menerapkan metode *soft voting* pada *ensemble learning* dengan menggabungkan arsitektur *Convolutional Neural Network* (CNN) ResNet-34, VGG16, dan MobileNetV2.
3. Hasil pelatihan model individu VGG16, ResNet-34, dan MobileNetV2 serta penggabungan dengan metode *soft voting* dievaluasi dengan metrik *accuracy*, *precision*, *recall*, dan *f1-score*.
4. Hasil pelatihan dan penggabungan model diimplementasikan ke dalam aplikasi berbasis web yang dibangun dengan bahasa pemrograman *python* dengan *library* *gradio*.