

KLASIFIKASI PENYAKIT DAUN ANGGUR MENGUNAKAN FINE-TUNED MOBILENETV3

Imam Baihaqi

Teknik Informatika, Universitas Negeri Semarang

Jl. Raya Banaran, Sekaran, Kec. Gn. Pati, Kota Semarang, Jawa Tengah 50229 Telp: (024) 86008700

Imambaihaq@students.unnes.ac.id¹

ABSTRAK

Tanaman anggur (*Vitis vinifera* L.) adalah komoditas hortikultura yang rentan terhadap penyakit yang disebabkan oleh berbagai faktor seperti lingkungan, cuaca, dan sebagainya. Deteksi dini dan akurat terhadap penyakit daun anggur memiliki peran krusial dalam mencegah penurunan produktivitas, meminimalkan kerugian ekonomi, serta mendukung penerapan pertanian presisi. Namun, identifikasi penyakit pada tanaman anggur masih banyak dilakukan secara manual, dimana rentan terhadap subjektivitas dan ketidakefisienan operasional. Penelitian ini bertujuan untuk mengembangkan sistem deteksi penyakit tanaman anggur menggunakan model *Convolutional Neural Network* (CNN) dengan pendekatan *transfer learning* menggunakan arsitektur MobileNetV3-Small, yang dirancang khusus untuk skenario terbatas dan memiliki kemampuan ekstraksi fitur yang baik untuk identifikasi penyakit tanaman anggur. Model ini dikembangkan menggunakan dataset dari Kaggle yang mencakup empat kelas, yaitu ESCA, Black Rot, Healthy, dan Leaf Blight. Metodologi penelitian meliputi pra-pemrosesan data, augmentasi citra, dan inisialisasi model MobileNetV3-Small dengan membekukan blok awal (1-9) serta membuka blok akhir (10-16) untuk dilatih ulang (*fine-tuning*). Hasil evaluasi menunjukkan bahwa strategi *fine-tuning* secara signifikan meningkatkan performa model dibandingkan model tanpa *fine-tuning*. Model yang diusulkan berhasil mencapai tingkat akurasi sebesar 99,83%, dengan *precision* 99,85%, *recall* 99,84%, dan *F1-score* 99,84%. Hasil ini menunjukkan bahwa MobileNetV3-Small dengan *fine-tuning* menawarkan keseimbangan optimal antara akurasi tinggi dan efisiensi komputasi, sehingga sangat potensial untuk diimplementasikan pada perangkat dengan sumber daya terbatas.

Kata kunci : Tanaman Anggur, Klasifikasi Penyakit, Deep Learning, MobileNetV3, Fine-Tuning, Transfer Learning.

1. PENDAHULUAN

Tanaman anggur (*Vitis vinifera* L.) merupakan salah satu komoditas hortikultura yang memiliki nilai ekonomi tinggi di dunia, baik untuk konsumsi segar maupun sebagai bahan baku industri anggur dan produk turunannya [1]. Di Indonesia, tanaman anggur telah dibudidayakan di beberapa daerah seperti Semarang, Lombok, dan Palu, dimana tidak hanya fokus pada produksi buah akan tetapi juga dengan menambahkan daya Tarik tambahan berupa integrasi agrowisata [2] [3] [4]. Namun, produktivitas tanaman anggur sangat dipengaruhi oleh serangan berbagai penyakit daun yang disebabkan oleh jamur, bakteri, maupun virus. Hal ini menjadi ancaman yang serius bagi produktivitas perkebunan anggur dan dapat menyebabkan penurunan kualitas hasil panen dan kerugian ekonomi [5]. Identifikasi dini dan akurat terhadap penyakit pada tanaman merupakan praktik yang paling kritis, untuk memperkecil dampak patogen terhadap hasil panen serta kualitas buah. Oleh sebab itu, identifikasi dini terhadap penyakit tanaman anggur, dalam hal ini adalah pada daunnya, penting untuk dilakukan dalam mendukung sistem pertanian yang lebih efektif, efisien, dan berkelanjutan [6].

Secara tradisional, identifikasi dini penyakit pada tanaman dilakukan secara manual oleh pakar tumbuhan atau petani yang berpengalaman. Akan tetapi, metode konvensional ini memiliki beberapa

batasan seperti subjektivitas penilaian, konsumsi waktu yang besar, biaya operasional yang tinggi, serta akurasi yang seringkali tidak konsisten [7] [8] [9]. Ketidakmampuan identifikasi dini seringkali mengakibatkan penyebaran penyakit yang terlanjur besar sebelum pencegahan dapat diterapkan. Oleh sebab itu, diperlukan sistem identifikasi otomatis yang cepat, akurat, serta mudah diimplementasikan. Pengembangan sistem berbasis *computer vision* dan *artificial intelligence* untuk identifikasi penyakit anggur menjadi solusi yang relevan, untuk mendeksi penyakit tanaman anggur secara dini sehingga tindakan pencegahan dapat diterapkan lebih cepat dan tepat.

Perkembangan *computer vision* dan *deep learning* yang pesat telah membuka paradigma baru dalam penyakit tanaman. *Convolutional Neural Network* (CNN) merupakan salah satu arsitektur paling populer dan telah terbukti efektif untuk tugas klasifikasi citra, secara otomatis mampu mengekstrak fitur dari data visual dengan baik tanpa memerlukan bantuan secara manual [10]. CNN dapat mempelajari fitur yang semakin abstrak seiring dengan kedalaman jaringan yang diterapkan, mulai dari fitur tingkat rendah hingga fitur tingkat tinggi yang dapat menangkap pola spesifik [11]. Kemampuan ini menjadikan CNN pilihan untuk deteksi penyakit

tanaman dengan tingkat akurasi yang mendekati kemampuan ahli manusia.

Salah satu tantangan umum dalam implementasi *deep learning* untuk deteksi penyakit tanaman adalah ketersediaan dataset yang terbatas. Hal ini mengakibatkan pelatihan model dari nol menjadi kurang efektif, karena CNN memerlukan sampel data yang cukup besar [12]. Oleh sebab itu, diperlukan pendekatan untuk mengatasi keterbatasan ini. *Transfer learning* dapat menjadi teknik yang efektif untuk melatih model dengan keterbatasan dataset. *Transfer Learning* memanfaatkan pengetahuan model yang dilatih pada dataset besar seperti *ImageNet* untuk kemudian digunakan pada tugas baru yang lebih spesifik [13].

Di antara model CNN yang tersedia, salah satu Model populer yang telah banyak digunakan adalah MobileNet. Model ini dikenal sebagai pilihan yang optimal untuk aplikasi klasifikasi obyek pada skenario *edge-computing* dan perangkat *mobile* [14]. Salah satu variannya, yaitu MobileNetV3, menawarkan latensi rendah dan konsumsi memori minimal tanpa mengorbankan kemampuan ekstraksi fitur yang kuat [15] [16].

Selain *transfer learning*, teknik *fine-tuning* menjadi langkah lanjutan untuk mengoptimalkan performa dari model. *Fine-tuning* dilakukan dengan membuka sebagian lapisan konvolusional tingkat tinggi untuk dilatih ulang, mempertahankan fitur tingkat rendah seperti deteksi tepi, fitur, dan bentuk dasar, serta melatih fitur tingkat tinggi yang lebih spesifik untuk menangkap karakteristik pada dataset baru [17].

Pada penelitian terdahulu, arsitektur CNN telah menunjukkan keberhasilan dalam klasifikasi penyakit daun anggur [18] [19] [20] [21]. Namun demikian, banyak penelitian tersebut menggunakan arsitektur yang relatif berat secara komputasi, yang kemungkinan akan membatasi implementasinya dalam skenario *real-time* di lapangan. Selain itu, penelitian mengenai klasifikasi penyakit daun tanaman anggur menggunakan model MobileNetV3 serta teknik *fine-tuning* masih terbatas, sehingga peluang untuk mengembangkan model tersebut masih terbuka.

Berdasarkan latar belakang tersebut, penelitian ini mengusulkan implementasi MobileNetV3-Small dengan strategi *fine-tuning* untuk klasifikasi penyakit daun anggur. Pendekatan ini diharapkan mampu menghasilkan model dengan akurasi tinggi serta ukuran model yang relatif ringan. Evaluasi performa dilakukan menggunakan metrik seperti akurasi, precision, recall, dan F1-score untuk memastikan keandalan model dalam mengklasifikasikan setiap kategori penyakit. Kemudian akan dijabarkan perbandingan antara Model tanpa *fine-tuning* dan model dengan *fine-tuning*, dengan menampilkan *confusion matrix* serta grafik pelatihan dari kedua skenario yang telah disampaikan.

2. TINJAUAN PUSTAKA

2.1. Tanaman Anggur (*Vitis vinifera* L.)


Tanaman anggur (*Vitis vinifera* L.) merupakan salah satu tanaman buah tertua yang telah dikembangkan secara domestikasi, dengan bukti munculnya pembuatan anggur pada aspek arkeologis dan data kimiawi pada periode Neolitikum di kawasan Selatan Kaukasus antara Laut Hitam dan Laut Kaspia [22]. Anggur mengandung konsentrasi polifenol yang signifikan, mencapai 300 mg per 100 gram bobot segar, yang mencakup senyawa bioaktif seperti *resveratrol*, *katekin*, *antosianin*, dan *flavanols* yang memiliki aktivitas antioksidan, anti-inflamasi, dan antikanker [22] [23]. Meski demikian, tanaman anggur rentan terhadap berbagai penyakit, dan kerentanannya bervariasi tergantung pada kultural dan kondisi lingkungan. Oleh sebab itu, identifikasi dini terhadap penyakit tanaman anggur yang akan muncul adalah hal yang penting [6].

2.2. Computer Vision dan Deep Learning

Computer Vision (CV) merupakan cabang kecerdasan buatan yang memungkinkan sistem komputer untuk menginterpretasi dan memahami informasi visual dari dunia nyata [24]. *Deep Learning*, sebagai subbidang *machine learning* yang menggunakan arsitektur jaringan saraf tiruan dengan banyak lapisan, mampu mengekstrak fitur kompleks secara otomatis tanpa rekayasa fitur manual sehingga menjadikannya ideal untuk tugas-tugas yang kompleks, serta populer digunakan dalam banyak penelitian. Salah satu arsitektur *deep learning* yang populer digunakan dalam penelitian penyakit tanaman adalah CNN.

2.3. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah arsitektur *deep learning* yang bekerja dengan beberapa lapisan untuk mengekstraksi fitur-fitur pada gambar dan mengklasifikasikan hasil ekstraksi fitur tersebut [25]. Lapisan pada CNN terdiri dari lapisan konvolusi untuk menerapkan filter dua dimensi untuk mendeteksi fitur lokal, kemudian ada lapisan *pooling* untuk mengurangi dimensi fitur yang diekstrak, dan terakhir adalah lapisan *dense* atau *fully connected* untuk mengklasifikasikan hasil fitur yang telah diekstrak. Ilustrasi dari struktur CNN secara umum dapat dilihat pada Gambar 1 [26].




Gambar 1. Struktur dasar Dari *Convolutional Neural Network* (CNN)

2.4. Transfer Learning

Transfer Learning memanfaatkan pengetahuan model yang dilatih pada dataset besar seperti ImageNet untuk kemudian digunakan pada tugas baru yang lebih spesifik [13]. Dengan menginisialisasi bobot yang optimal pada pelatihan sebelumnya, teknik ini akan mempercepat konvergensi pelatihan dan meningkatkan generalisasi jika dibandingkan dengan melatih model dari nol [27]. Salah satu model CNN yang telah dilatih menggunakan dataset ImageNet adalah MobileNetV3.

2.5. MobileNetV3

MobileNetV3 adalah model CNN yang dirancang untuk dioptimalkan pada perangkat mobile dan *edge computing* [14]. Model ini mengintegrasikan *inverted residual blocks*, *squeeze-and-excitation modules*, serta fungsi aktivasi *hard-swish* untuk mencapai performa yang optimal antara akurasi dan komputasi yang efisien [28]. MobileNetV3 tersedia dalam dua varian, yaitu MobileNetV3-Large dan MobileNetV3-Small yang dirancang untuk lingkungan dengan keterbatasan sumber daya komputasi dan hanya memiliki sekitar 1,5 juta parameter. Ilustrasi struktur dari MobileNetV3 dapat dilihat pada Gambar 2.



Gambar 2. Struktur MobileNetV3

2.6. Fine-Tuning

Fine-Tuning adalah teknik yang dilakukan pada model CNN dengan membuka sebagian lapisan konvolusional tingkat tinggi untuk dilatih ulang, mempertahankan fitur tingkat rendah seperti deteksi tepi, fitur, dan bentuk dasar, serta melatih fitur tingkat tinggi yang lebih spesifik untuk menangkap karakteristik pada dataset baru [17]. Teknik ini memungkinkan model mempertahankan pengetahuan umum dari data awal sekaligus mempelajari fitur khusus dari data target baru secara efisien. Dengan demikian, teknik ini efektif dalam memanfaatkan representasi fitur yang sudah ada, sembari meningkatkan performa pada tugas baru.

2.7. Penelitian Terdahulu


Beberapa penelitian terdahulu telah menerapkan *deep learning* dan teknik *transfer learning* dalam tugas klasifikasi penyakit daun anggur. Jain dan Periyasamy [18] mengimplementasikan transfer learning menggunakan VGG16 sebagai ekstraktor fitur dengan klasifikasi Random Forest untuk deteksi penyakit anggur, mencapai akurasi 91.66% pada dataset empat kelas penyakit. Kunduracioglu dan Pacal [20]

melakukan studi komprehensif membandingkan 14 arsitektur CNN dan 17 Vision Transformer, menemukan bahwa kombinasi CNN-ViT dapat mencapai akurasi 100% pada dataset Grapevine dan PlantVillage, meskipun dengan biaya komputasi yang tinggi. Prasad et al. [21] mengembangkan DCNN classifier berbasis VGG16 yang dimodifikasi dengan menambahkan lapisan konvolusional tambahan, berhasil mencapai akurasi 99.06% pada klasifikasi multiclass penyakit daun anggur. Darmawan et al. [22] mengusulkan pendekatan hybrid menggunakan EfficientNet sebagai ekstraktor fitur dengan CatBoost classifier, menunjukkan efektivitas kombinasi deep learning dan machine learning tradisional untuk klasifikasi penyakit daun anggur.

Disimpulkan, beberapa penelitian sebelumnya menggunakan arsitektur berat dengan jutaan parameter, dimana ini kurang cocok untuk skenario tertentu seperti *edge computing*. Selain itu, penelitian sebelumnya belum ada yang menerapkan model MobileNetV3 dengan strategi *fine-tuning*.

3. METODE PENELITIAN

Penelitian ini mengimplementasikan Arsitektur *Convolutional Neural Network* (CNN) untuk klasifikasi penyakit tanaman daun dengan model MobileNetV3-Small. Pengembangan model dilakukan pada platform Kaggle dengan memanfaatkan GPU P100. Bahasa Pemrograman yang digunakan adalah Python dan library PyTorch.




Gambar 3. Diagram Alur Pengembangan Model Fine-tuned MobileNetV3-Small

Alur pengembangan model secara keseluruhan dijabarkan pada Gambar 3. Pengembangan model diawali dengan pengumpulan data citra daun anggur yang mencakup empat kategori, yaitu ESCA, *Black Rot*, *Leaf Blight*, dan *Healthy*. Selanjutnya, data citra kemudian masuk ke bagian pra-pemrosesan yang mencakup pembagian data menjadi data latih, data validasi, dan data uji, yang kemudian dilanjutkan dengan teknik augmentasi untuk menambah variasi data dan normalisasi untuk meningkatkan kualitas input. Setelahnya, arsitektur MobileNetV3-Small diinisialisasi menggunakan pendekatan *transfer learning*, serta diterapkan teknik *fine-tuning* dengan teknis blok awal (1-9) dibekukan untuk mempertahankan fitur dasar, sementara blok akhir (13-16) dibuka (*unfreeze*) dan digabungkan dengan *custom classifier* untuk menyesuaikan spesifikasi data baru.

Setelah model melalui tahap pelatihan dan validasi, performa akhirnya diukur secara komprehensif melalui fase evaluasi yang menggunakan berbagai metrik statistik, mulai dari *accuracy*, *precision*, *recall*, dan *F1-Score*, hingga analisis mendalam melalui Confusion Matrix serta kurva ROC dan nilai AUC.

Dataset yang digunakan pada penelitian ini adalah *Grapevine Disease Dataset (Original)* [29]. Dataset ini didapatkan dari platform Kaggle. Terdapat total 9027 sampel gambar dan empat kelas pada dataset ini, yaitu *ESCA*, *Black Rot*, *Healthy*, dan *Leaf Blight*. Dataset kemudian dibagi menjadi tiga subset, yaitu *train*, *validation*, dan *test* dengan proporsi sekitar 64%:16%:20%. Pada set *train*, terdapat 1510 sampel *Black Rot*, 1536 sampel *ESCA*, 1353 sampel *Healthy*, dan 1377 sampel *Leaf Blight*. Kemudian pada set *validation*, terdapat 378 sampel *Black Rot*, 384 sampel *ESCA*, 339 sampel *Healthy*, dan 345 sampel *Leaf Blight*. Terakhir, pada set *test*, terdapat 472 sampel *Black Rot*, 480 sampel *ESCA*, 423 sampel *Healthy*, dan 430 sampel *Leaf Blight*.



Gambar 4. Sampel augmentasi pada masing-masing kelas

Tahap Pertama yang dilakukan adalah memastikan dataset siap digunakan. Setelah pembagian set menjadi *train*, *validation*, dan *test*, maka selanjutnya dilakukan serangkaian transformasi citra untuk meningkatkan variasi data pelatihan. Seluruh sampel diubah ukurannya agar seragam menjadi 224x224. Pada data *train*, diterapkan augmentasi untuk meningkatkan variasi citra dan mengurangi risiko *overfitting*, berupa *rotation*, *horizontal flip*, *translation*, *shear*, *color jitter*, dan *random resized crop*. Setelah proses augmentasi, setiap sampel citra dikonversi menjadi tensor dan dilakukan normalisasi menggunakan nilai *mean* [0,485; 0,456; 0,406] dan *standard deviation* [0,229; 0,224; 0,225], yang merupakan standar normalisasi dataset ImageNet. Sampel citra yang telah dilakukan augmentasi dapat dilihat pada Gambar 4.

Setelah proses augmentasi dan normalisasi data, arsitektur MobileNetV3-Small diinisialisasi. Pada tahap awal, seluruh parameter model dibekukan dengan mengatur *requires_grad* menjadi *false*. Hal ini bertujuan agar mempertahankan fitur umum yang telah dipelajari seperti tekstur, tepi, serta bentuk dan pola umum pada citra. Selanjutnya, dilakukan proses *fine-tuning* dengan membuka kembali beberapa lapisan terakhir dari *feature extractor*, yaitu mulai dari layer indeks ke-10 hingga layer terakhir. Setelah itu, bagian *classifier* asli pada MobileNetV3-Small diganti dengan arsitektur klasifikasi kustom. Lapisan klasifikasi yang diterapkan terdiri dari dua lapisan *fully connected* dengan ukuran 256 dan 128 *neuron*. Masing-masing lapisan *fully connected* diikuti oleh *batch normalization*, fungsi aktivasi *hardswish*, serta dropout sebesar 0,5 dan 0,3 untuk mematikan beberapa neuron selama proses pelatihan sehingga memaksa seluruh neuron untuk tidak bergantung pada neuron yang pintar, serta mengurangi risiko *overfitting*. Lapisan terakhir merupakan *fully connected layer* yang disesuaikan dengan jumlah kelas pada dataset.

Dalam Proses pelatihan, digunakan fungsi *CrossEntropyLoss* yang sesuai untuk tugas klasifikasi *multi-class*. Optimasi parameter dilakukan menggunakan algoritma AdamW, dengan *learning rate* 0,0001 dan *weight decay* sebesar 0,0001, serta *batch size* sebesar 8. Selama proses pelatihan, performa dari model dipantau oleh fungsi *EarlyStopping* dan *Model Checkpoint* untuk menyimpan hasil terbaik dari pelatihan model pada setiap epoch, serta menghentikan pelatihan apabila ada indikasi *overfitting*. Selain itu, juga ditambahkan fungsi *ReduceLROnPlateau*, yang akan menurunkan *learning rate* ketika pelatihan model mencapai *plateau*. Setelah pelatihan selesai, model yang telah dilatih kemudian diuji pada data *test* untuk melatih kemampuan model pada sampel data yang belum pernah dilihat sebelumnya. Rangkaian pelatihan ini diharapkan dapat menyajikan kemampuan model secara komprehensif.

Setelah pengujian selesai, model kemudian dievaluasi untuk melihat bagaimana hasil dari model. Evaluasi dilakukan menggunakan beberapa metrik, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu, digunakan *confusion matrix* untuk melihat distribusi prediksi pada setiap kelas. Confusion matrix memberikan informasi rinci mengenai jumlah *true positive*, *true negative*, *false positive*, dan *false negative* untuk masing-masing kelas, sehingga memungkinkan identifikasi pola kesalahan klasifikasi. Rumus untuk masing-masing evaluasi adalah sebagai berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

4. HASIL DAN PEMBAHASAN

Penelitian ini mengembangkan model CNN berbasis arsitektur MobileNetV3-Small dengan pendekatan *transfer learning*, untuk tugas klasifikasi penyakit daun anggur. Pendekatan dilakukan dengan melatih model MobileNetV3-Small tanpa dilakukan *fine-tuning* pada lapisannya dan melatih model MobileNetV3-Small dengan membuka blok 10 sampai blok 16 untuk dilatih kembali pada tugas baru, yang dalam hal ini adalah klasifikasi penyakit daun anggur. Setiap pendekatan dilatih dengan *optimizer* yang sama, yaitu AdamW dengan *learning rate* 0,0001 dan *weight decay* sebesar 0,0001, *batch size* sebesar 8, dan *epoch* sebesar 25. Evaluasi model menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score*.

Hasil evaluasi pelatihan dari model MobileNetV3-Small secara umum dapat dilihat pada Tabel 1. Secara umum, performa MobileNetV3-Small dengan membuka sebagian lapisan pada *feature extractor* menghasilkan performa yang lebih baik daripada MobileNetV3-Small yang membekukan seluruh lapisan *feature extractor* nya.

Pada Skenario tanpa *fine-tuning*, model memperoleh nilai loss sebesar 0,0585 dengan *accuracy* 0,9778, *precision* 0,9790, *recall* 0,9778, dan F1-score 0,9785. Nilai-nilai tersebut sebenarnya telah menunjukkan bahwa model sudah mampu melakukan klasifikasi dengan baik, ditandai dengan tingkat akurasi yang mendekati 98%, serta keseimbangan antara *precision* dan *recall* yang tercermin pada nilai F1-score yang tinggi.


Namun, ketika model dilakukan *fine-tuning*, performa model meningkat secara konsisten di seluruh

metrik evaluasi. Nilai loss menurun drastis menjadi 0,0118, dimana ini mengindikasikan kekeliruan prediksi yang mengecil. Selain itu, *accuracy* meningkat menjadi 0,9983, *precision* menjadi 0,9985, *recall* menjadi 0,9984, dan *F1-score* mencapai 0,9984. Peningkatan ini menunjukkan bahwa proses *fine-tuning* mampu mengoptimalkan bobot model, sehingga lebih adaptif terhadap karakteristik dataset penyakit daun anggur.

Performa dari Model MobileNetV3-Small ini juga diperkuat dengan hasil *confusion matrix* yang dapat dilihat pada Gambar 5. Pada Gambar 5(a) yang menampilkan model MobileNetV3-Small tanpa *fine-tuning*, masih ditemukan beberapa kesalahan klasifikasi pada beberapa kelas. Kelas *Black rot*, dari total 472 data uji, sebanyak 435 data berhasil diklasifikasikan dengan benar. Namun, terdapat 34 data yang salah diprediksi sebagai kelas ESCA dan 3 data salah diprediksi sebagai kelas Leaf Blight. Pada kelas ESCA, sebanyak 478 dari 480 data berhasil diprediksi dengan benar, sementara masing-masing 1 data salah diklasifikasikan ke kelas *Black Rot* dan *Healthy*. Kelas *Healthy* menunjukkan performa terbaik dengan 423 prediksi benar tanpa kesalahan. Terakhir pada kelas *Leaf blight* sebanyak 429 data berhasil diprediksi dengan benar dengan hanya 1 data yang salah diklasifikasikan sebagai kelas *Healthy*. Secara keseluruhan, *confusion matrix* pada model tanpa *fine-tuning* menunjukkan bahwa kesalahan klasifikasi masih terjadi terutama pada kelas yang memiliki kemiripan pola visual antar penyakit.

Tabel 1. Hasil Pelatihan MobileNetV3 pada tugas klasifikasi penyakit daun anggur

Strategi	Loss	Accuracy	Precision	Recall	F1-Score
Tanpa Fine-Tuning	0.0585	0.9778	0.9790	0.9778	0.9785
Fine-Tuning	0.0118	0.9983	0.9985	0.9984	0.9984




Gambar 5. *Confusion Matrix* Model MobileNetV3-Small tanpa *fine-tuning* (kiri) dan Model MobileNetV3-Small dengan *Fine-Tuning* (Kanan)

Sementara itu, pada Gambar 5(b), confusion matrix model MobileNetV3-Small dengan *fine-tuning* menunjukkan peningkatan performa yang sangat signifikan. Hampir seluruh data berhasil diklasifikasikan secara sempurna pada diagonal utama. Pada Kelas *Black rot*, sebanyak 469 data berhasil diprediksi dengan benar dengan hanya 3 data yang salah diprediksi sebagai kelas *ESCA*. Selanjutnya, kelas *ESCA* menunjukkan hasil sempurna dengan seluruh 480 data berhasil diklasifikasikan secara benar tanpa kesalahan. Hal serupa juga terjadi pada kelas *Healthy* dan *Leaf Blight*, dimana seluruh data masing-masing sebanyak 423 dan 430 berhasil diprediksi dengan tepat tanpa adanya salah klasifikasi ke kelas lain. Tidak ditemukan kekeliruan klasifikasi pada sebagian besar kelas menunjukkan bahwa proses *fine-tuning* berhasil meningkatkan kemampuan model dalam membedakan karakteristik antar kelas penyakit daun anggur secara lebih presisi dan konsisten.


Gambar 6 menampilkan proses pelatihan model tanpa *fine-tuning*. Grafik akurasi memperlihatkan peningkatan bertahap pada data training dari sekitar 0,76 hingga mendekati 0,93 di akhir epoch, sedangkan akurasi validasi berada pada rentang yang lebih tinggi dan relatif stabil di kisaran 0,95–0,98. Sementara itu, grafik loss menunjukkan penurunan signifikan pada beberapa epoch awal, kemudian melandai seiring bertambahnya epoch. Meskipun kurva training dan validasi tidak menunjukkan indikasi *overfitting*, masih terdapat jarak antara performa training dan validasi yang menandakan bahwa model belum sepenuhnya mengoptimalkan bobot fitur terhadap karakteristik dataset.

Sedangkan, pada Gambar 7 yang menampilkan proses pelatihan model dengan *fine-tuning*, model dapat menghasilkan performa yang lebih konsisten serta konvergensi yang lebih baik. Akurasi training meningkat secara signifikan hingga mendekati 0,98, sementara akurasi validasi hampir menyentuh 1,00 dan cenderung stabil di akhir pelatihan. Grafik loss juga menunjukkan penurunan yang lebih tajam dibandingkan model tanpa *fine-tuning*, dengan nilai loss training dan validasi yang semakin kecil serta selisih yang minimal. Hasil ini mengindikasikan bahwa penerapan *fine-tuning* dapat membantu model menyesuaikan bobot lebih spesifik terhadap dataset penyakit daun anggur, sehingga dapat menghasilkan generalisasi yang lebih baik dan performa klasifikasi yang lebih konsisten, sebagaimana telah terlihat pada nilai evaluasi dan confusion matrix sebelumnya.

Hasil ini menunjukkan bahwa Model MobileNetV3-Small menghasilkan performa yang kompetitif dibandingkan dengan penelitian sebelumnya. Model yang diusulkan mampu mencapai akurasi sebesar 99,83% dengan nilai precision, recall, dan F1-score yang hampir sempurna, melampaui penelitian dari [18] yang memperoleh akurasi 91,66%, serta lebih tinggi dibandingkan modifikasi VGG16 oleh [20] yang mencapai 99,06%, dan [22] yang mencapai akurasi 99,56%. Meskipun penelitian [19] melaporkan akurasi hingga 100% melalui kombinasi CNN dan *Vision Transformer*, pendekatan tersebut memiliki kompleksitas arsitektur dan biaya komputasi yang lebih tinggi. Dengan demikian, MobileNetV3-Small dengan *fine-tuning* menawarkan keseimbangan yang optimal antara akurasi yang sangat tinggi dan efisiensi komputasi, menjadikannya solusi yang efektif untuk klasifikasi penyakit daun anggur.



Gambar 6. Grafik Akurasi dan Loss saat training dan validasi untuk Model tanpa *fine-tuning*



Gambar 7. Grafik Akurasi dan Loss saat training dan validasi untuk Model dengan *fine-tuning*

5. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa arsitektur MobileNetV3-small menggunakan teknik *fine-tuning* dengan membuka sebagian lapisan *feature extractor* menghasilkan performa klasifikasi penyakit pada daun anggur ke dalam empat kelas, yaitu Black Rot, ESCA, Healthy, dan Leaf Blight dengan sangat baik. Model dengan *fine-tuning* memperoleh *accuracy* sebesar 99,83%, *precision* 99,85%, *recall* 99,84%, dan *F1-score* 99,84%, serta menunjukkan nilai loss yang lebih rendah dan *confusion matrix* yang hampir sempurna. Hasil ini membuktikan bahwa kombinasi arsitektur lightweight MobileNetV3-Small dan teknik *fine-tuning* mampu menghasilkan performa klasifikasi yang sangat tinggi sekaligus tetap efisien secara komputasi.

Penelitian ini masih memiliki beberapa keterbatasan, seperti penggunaan dataset yang sebagian besar diperoleh pada kondisi pencahayaan dan latar belakang yang relatif terkontrol, sehingga kemampuan generalisasi model pada kondisi lapangan nyata masih perlu diuji lebih lanjut. Untuk pengembangan pada penelitian selanjutnya, dapat dilakukan dengan menguji model pada dataset yang lebih beragam dan kondisi lingkungan nyata (*real-world scenario*) guna menguji kemampuan generalisasi model terhadap variasi pencahayaan, sudut pengambilan gambar, dan latar belakang yang lebih kompleks. Selain itu, implementasi model pada perangkat *edge* atau aplikasi *mobile* dapat dilakukan untuk mengevaluasi performa inferensi secara langsung di lapangan. Penelitian selanjutnya juga dapat membandingkan berbagai skema *fine-tuning*, seperti variasi jumlah blok yang dibuka atau penggunaan teknik regularisasi tambahan.

DAFTAR PUSTAKA

- [1] A. Amores-Arrocha and A. Jiménez-Cantizano, "Genetic Resources for Viticulture," *Horticulturae*, vol. 11, no. 4, p. 362, Mar. 2025, doi: 10.3390/horticulturae11040362.
- [2] H. Herdiana, N. Mappanganro, and N. Nirmawati, "Science and Technology Women Farmers' Through Grape Cultivation (*Vitis vinifera* L)," *Unram J. Community Serv.*, vol. 6, no. 1, pp. 48–52, Mar. 2025, doi: 10.29303/ujcs.v6i1.896.
- [3] Y. Yunita, M. A. I. Yunus, K. Mirbah, M. A. U. N, and S. Sukmawati, "Menguak Potensi Tersembunyi Kebun Anggur: Analisis Pengelolaan dan SOP Agro Secino dalam Memenuhi Kebutuhan Pasar," *J. Ekon. Pertan. Dan Agribisnis*, vol. 2, no. 2, pp. 88–95, Nov. 2024, doi: 10.62379/jepag.v2i1.2246.
- [4] U. Azwarni, M. Mappatoba, and C. Christoporus, "STRATEGY FOR DEVELOPING DUYU BANGBIT VINE GARDEN AGROTOURISM IN DUYU VILLAGE, TATANGA DISTRICT, PALU CITY," *AGROLAND Agric. Sci. J. E-J.*, vol. 12, no. 1, pp. 15–21, Jun. 2025, doi: 10.22487/agroland.v12i1.2342.
- [5] Z. Chen, J. Feng, K. Zhu, Z. Yang, Y. Wang, and M. Ren, "YOLOv8-ACCW: Lightweight Grape Leaf Disease Detection Method Based on Improved YOLOv8," *IEEE Access*, vol. 12, pp. 123595–123608, 2024, doi: 10.1109/ACCESS.2024.3453379.
- [6] B. Cohen, Y. Edan, A. Levi, and V. Alchanatis, "Early Detection of Grapevine (*Vitis vinifera*) Downy Mildew (*Peronospora*) and Diurnal Variations Using Thermal Imaging," *Sensors*, vol. 22, no. 9, p. 3585, May 2022, doi: 10.3390/s22093585.
- [7] M. Shoaib *et al.*, "An advanced deep learning models-based plant disease detection: A review of recent research," *Front. Plant Sci.*, vol. 14, p. 1158933, Mar. 2023, doi: 10.3389/fpls.2023.1158933.
- [8] M. Shafay *et al.*, "Recent advances in plant disease detection: challenges and opportunities," *Plant Methods*, vol. 21, no. 1, p. 140, Oct. 2025, doi: 10.1186/s13007-025-01450-0.

- [9] A. Abbas *et al.*, "Drones in Plant Disease Assessment, Efficient Monitoring, and Detection: A Way Forward to Smart Agriculture," *Agronomy*, vol. 13, no. 6, p. 1524, May 2023, doi: 10.3390/agronomy13061524.
- [10] W. Fang, S. Tang, D. Yan, X. Dai, W. Zhang, and J. Xiong, "Breast cancer pathology image recognition based on convolutional neural network," *PLOS One*, vol. 20, no. 5, p. e0311728, May 2025, doi: 10.1371/journal.pone.0311728.
- [11] J. Luo and D. Hu, "An Image Classification Method Based on Adaptive Attention Mechanism and Feature Extraction Network," *Comput. Intell. Neurosci.*, vol. 2023, no. 1, p. 4305594, Jan. 2023, doi: 10.1155/2023/4305594.
- [12] M. Rezaei, D. Diepeveen, H. Laga, M. G. K. Jones, and F. Sohel, "Plant disease recognition in a low data scenario using few-shot learning," *Comput. Electron. Agric.*, vol. 219, p. 108812, Apr. 2024, doi: 10.1016/j.compag.2024.108812.
- [13] N. Abou Baker, N. Zengeler, and U. Handmann, "A Transfer Learning Evaluation of Deep Neural Networks for Image Classification," *Mach. Learn. Knowl. Extr.*, vol. 4, no. 1, pp. 22–41, Jan. 2022, doi: 10.3390/make4010002.
- [14] B. S. Sharmila, H. S. Santhosh, S. Parameshwara, M. S. Swamy, W. H. Baig, and S. V. Nanditha, "Optimizing Deep Learning Networks for Edge Devices with an Instance of Skin Cancer and Corn Leaf Disease Dataset," *SN Comput. Sci.*, vol. 4, no. 6, p. 793, Oct. 2023, doi: 10.1007/s42979-023-02239-5.
- [15] "A new lightweight network based on MobileNetV3," *KSII Trans. Internet Inf. Syst.*, vol. 16, no. 1, Jan. 2022, doi: 10.3837/tiis.2022.01.001.
- [16] Z. Duan and H. Liu, "Improving Network Structure for Efficient Classification Network Based on MobileNetV3," *IEEE Access*, vol. 13, pp. 191296–191308, 2025, doi: 10.1109/ACCESS.2025.3630207.
- [17] A. Rotimi Philip, "Fine-Tuning Depth Analysis: Identifying the Sweet Spot for Maximum Accuracy in CNNs," *Int. J. Sci. Res. Comput. Sci. Eng.*, 2025, doi: <https://doi.org/10.26438/ijsrcse.v13i3.703>.
- [18] B. Jain and S. Periyasamy, "Grapes disease detection using transfer learning".
- [19] I. Kunduracioglu and I. Pacal, "Advancements in deep learning for accurate classification of grape leaves and diagnosis of grape diseases," *J. Plant Dis. Prot.*, vol. 131, no. 3, pp. 1061–1080, Jun. 2024, doi: 10.1007/s41348-024-00896-z.
- [20] K. V. Prasad, H. Vaidya, C. Rajashekhar, K. S. Karekal, R. Sali, and K. S. Nisar, "Multiclass classification of diseased grape leaf identification using deep convolutional neural network(DCNN) classifier," *Sci. Rep.*, vol. 14, no. 1, p. 9002, Apr. 2024, doi: 10.1038/s41598-024-59562-x.
- [21] A. Y. Darmawan, Y. M. P. Tanga, and J. Unjung, "Grape leaf disease classification using efficientnet feature extraction and catboostclassifier," *J. Soft Comput. Explor.*, vol. 6, no. 1, pp. 1–8, Mar. 2025, doi: 10.52465/josce.v6i1.507.
- [22] M. Harutyunyan and M. Malfeito-Ferreira, "The Rise of Wine among Ancient Civilizations across the Mediterranean Basin," *Heritage*, vol. 5, no. 2, pp. 788–812, Apr. 2022, doi: 10.3390/heritage5020043.
- [23] D.-D. Zhou *et al.*, "Bioactive Compounds, Health Benefits and Food Applications of Grape," *Foods*, vol. 11, no. 18, p. 2755, Sep. 2022, doi: 10.3390/foods11182755.
- [24] M. El Sakka, M. Ivanovici, L. Chaari, and J. Mothe, "A Review of CNN Applications in Smart Agriculture Using Multimodal Data," *Sensors*, vol. 25, no. 2, p. 472, Jan. 2025, doi: 10.3390/s25020472.
- [25] M. Krichen, "Convolutional Neural Networks: A Survey," *Computers*, vol. 12, no. 8, p. 151, Jul. 2023, doi: 10.3390/computers12080151.
- [26] X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, "A review of convolutional neural networks in computer vision," *Artif. Intell. Rev.*, vol. 57, no. 4, p. 99, Mar. 2024, doi: 10.1007/s10462-024-10721-6.
- [27] D. Sinanc Terzi, "Effect of different weight initialization strategies on transfer learning for plant disease detection," *Plant Pathol.*, vol. 73, no. 9, pp. 2325–2343, Dec. 2024, doi: 10.1111/ppa.13997.
- [28] R. Ochoa-Ornelas, A. Gudiño-Ochoa, A. Y. Rodríguez González, L. Trujillo, D. Fajardo-Delgado, and K. L. Puga-Nathal, "Lightweight and Accurate Deep Learning for Strawberry Leaf Disease Recognition: An Interpretable Approach," *AgriEngineering*, vol. 7, no. 10, p. 355, Oct. 2025, doi: 10.3390/agriengineering7100355.
- [29] R. Mandal, "Grapevine Disease Dataset (Original)," Grapevine Disease Dataset (Original). Accessed: Feb. 24, 2026. [Online]. Available: <https://www.kaggle.com/datasets/rm1000/grape-disease-dataset-original>