

Klasifikasi Penyakit Daun Anggur Menggunakan Metode CNN Berbasis Arsitektur EfficientNetB6

M. Ryan Nurdiansyah N.A

Informatika, Universitas Pembangunan Nasional "Veteran" Jawa Timur

21081010321@student.upnjatim.ac.id

Abstrak— *Vitis vinifera* atau tanaman anggur merupakan komoditas bernilai ekonomi tinggi yang mudah terserang berbagai penyakit daun, di antaranya *Black Rot*, *Black Measles*, dan *Leaf Blight*, selain kategori daun sehat (*Healthy Leaves*). Proses deteksi penyakit secara manual umumnya memakan waktu yang relatif lama dan bergantung pada subjektivitas pengamat. Oleh karena itu, dibutuhkan suatu sistem otomatis yang memanfaatkan teknologi pengolahan citra digital dan metode deep learning untuk meningkatkan efisiensi serta objektivitas proses identifikasi penyakit. Penelitian ini bertujuan mengembangkan model klasifikasi penyakit daun anggur dengan empat kelas menggunakan arsitektur *Convolutional Neural Network* (CNN) *EfficientNetB6*. Dataset yang digunakan berasal dari *Grape400* di Kaggle dan diperluas melalui augmentasi menjadi tiga kali lipat dari jumlah aslinya. Model dilatih selama 50 epoch dengan optimizer Adam dan learning rate 1×10^{-4} . Hasil pengujian pada data uji menunjukkan bahwa model mencapai akurasi keseluruhan sebesar 98,8%, dengan nilai rata-rata makro untuk precision, recall, dan F1-score sebesar 0,988. Hal ini mengindikasikan bahwa model memiliki performa klasifikasi yang konsisten pada setiap kelas. Kelas *HealthyGrapes* terdeteksi sempurna, sedangkan *LeafBlight* mendekati sempurna, dan kelas *BlackMeasles* serta *BlackRot* masing-masing mempertahankan nilai f1-score 0,977. Hasil ini menunjukkan bahwa *EfficientNetB6* mampu mengekstraksi fitur morfologis dan tekstural daun anggur secara efektif, serta memiliki kemampuan generalisasi tinggi tanpa indikasi overfitting. Pendekatan ini berpotensi dikembangkan menjadi sistem bantu keputusan untuk deteksi dini penyakit daun anggur berbasis citra digital.

Kata Kunci— Tanaman Anggur, CNN, *EfficientNetB6*, Klasifikasi Citra, Deep Learning

I. PENDAHULUAN

Anggur (*Vitis vinifera*) merupakan tanaman yang secara luas dibudidayakan di wilayah beriklim tropis dan subtropis karena memiliki nilai ekonomi tinggi [1]. Tanaman anggur sangat rentan terhadap berbagai penyakit daun yang disebabkan oleh jamur, bakteri, maupun virus, seperti *downy mildew*, *powdery mildew*, *black rot*, dan *leaf blight*. Penyakit-penyakit ini dapat menurunkan kualitas buah, memperlambat pertumbuhan tanaman, dan menyebabkan kerugian ekonomi bagi petani jika tidak dideteksi sejak dini [2].

Identifikasi penyakit daun anggur secara manual umumnya dilakukan melalui pengamatan visual oleh ahli, namun metode ini cenderung memerlukan waktu lama, bersifat subjektif, serta kurang efektif pada tahap awal infeksi karena kemiripan gejala antarpenyakit [3]. Seiring dengan kemajuan teknologi dan kecerdasan buatan, pendekatan berbasis citra digital dengan *deep learning* mulai digunakan untuk mengidentifikasi penyakit tanaman secara otomatis dan cepat [4]. *Deep learning* mampu mengenali pola visual kompleks seperti perubahan warna, bentuk, serta tekstur daun yang sulit dibedakan secara manual [5].

Salah satu arsitektur jaringan saraf konvolusional yang banyak digunakan dalam klasifikasi citra penyakit tanaman adalah *EfficientNet*, yang dikenal karena memiliki keseimbangan optimal antara akurasi dan efisiensi komputasi melalui teknik compound scaling, yaitu pengaturan proporsional antara kedalaman, lebar, dan resolusi jaringan [6]. Penelitian yang dilakukan [6] memanfaatkan arsitektur *EfficientNetB0* bersama *InceptionV3* dan *Xception* dalam proses identifikasi penyakit daun anggur, menunjukkan efektivitas pendekatan deep learning dalam mendeteksi gejala pada tingkat visual yang kompleks. Hasil penelitian menunjukkan bahwa model *EfficientNetB0* menghasilkan performa terbaik dengan nilai accuracy sebesar 99,5%, f1-score 0,995, dan AUC 1,00. Selain itu, model ini memiliki jumlah parameter yang paling sedikit serta waktu inferensi tercepat, sehingga dinilai efisien untuk diterapkan pada sistem deteksi penyakit tanaman secara *real-time*.

Penelitian selanjutnya [7] menggunakan arsitektur VGG16 berbasis CNN dengan segmentasi *k-means clustering* dan memperoleh akurasi hingga 97,25%, menunjukkan bahwa model CNN mampu mengenali fitur citra daun dengan baik. Selanjutnya Penelitian [8] menunjukkan bahwa kombinasi *EfficientNetB0* dan *CatBoost* mampu mengklasifikasikan penyakit daun anggur dengan akurasi tinggi, mencapai 99,56%. Hasil ini membuktikan efektivitas *EfficientNet* dalam mengekstraksi fitur citra daun secara efisien. Selanjutnya penelitian [9] melakukan analisis komparatif antara CNN, *EfficientNet*, dan *ResNet* untuk klasifikasi penyakit daun anggur. Hasil penelitian menunjukkan bahwa *EfficientNet* mencapai akurasi sebesar 97%, lebih tinggi dibandingkan CNN (90%) meskipun sedikit di bawah *ResNet* (98%), yang menunjukkan efisiensi dan kinerja optimal *EfficientNet* dalam klasifikasi penyakit daun anggur. Namun demikian, berbagai penelitian tersebut masih menghadapi tantangan pada aspek efisiensi komputasi dan kemampuan generalisasi model terhadap kondisi nyata di lapangan, seperti variasi pencahayaan, ukuran daun, latar belakang kompleks, serta jenis penyakit yang berbeda-beda [10].

Berdasarkan uraian tersebut, penelitian ini berfokus pada pengembangan sistem klasifikasi penyakit daun anggur menggunakan arsitektur *EfficientNetB6*. Penelitian [11] telah melakukan identifikasi penyakit daun anggur menggunakan arsitektur *Convolutional Neural Network* (CNN) konvensional dengan empat kelas utama, yaitu *Black Rot*, *Esca*, *Leaf Blight*, dan *Healthy*, dan memperoleh akurasi sebesar 91,37%. Hasil tersebut menunjukkan bahwa pendekatan *deep learning* berbasis CNN memiliki potensi besar dalam mendeteksi penyakit tanaman, namun arsitektur CNN standar masih memiliki keterbatasan dalam kedalaman jaringan dan kemampuan ekstraksi fitur kompleks. Untuk mengatasi hal tersebut, penelitian ini menggunakan arsitektur

EfficientNetB6 yang menerapkan strategi *compound scaling* guna menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara proporsional. Dengan pendekatan ini, diharapkan model dapat mengekstraksi fitur morfologis daun secara lebih optimal, meningkatkan akurasi klasifikasi, serta mendukung pengembangan sistem diagnosis penyakit daun anggur otomatis berbasis *smart farming* yang efisien dan berkelanjutan.

II. KAJIAN PUSTAKA

A. Pengolahan Citra Digital

Pengolahan citra digital merupakan disiplin dalam ilmu komputer yang memanfaatkan algoritma komputasional untuk melakukan proses manipulasi dan analisis terhadap citra, dengan tujuan mengekstraksi serta memperoleh informasi visual yang signifikan dan bernilai analitis. Dalam bidang pertanian, teknik ini dimanfaatkan untuk mendeteksi, mengidentifikasi, dan mengklasifikasikan gejala penyakit tanaman secara otomatis melalui analisis citra pada bagian daun, batang, maupun buah. Berdasarkan penelitian sebelumnya, teknik pengolahan citra digital mampu mendeteksi, mengukur, serta mengklasifikasikan penyakit tanaman dari citra digital pada spektrum tampak dengan hasil yang objektif dan dapat direproduksi [12].

Citra berbasis sensor RGB semakin banyak dimanfaatkan dalam penelitian karena menawarkan biaya akuisisi yang ekonomis dan kemudahan penerapan di lingkungan lapangan, sehingga metode ini menjadi salah satu pendekatan utama dalam diagnosis penyakit tanaman. Umumnya, tahapan dalam pengolahan citra mencakup pengambilan gambar, pra-pemrosesan, pemisahan objek (segmentasi), pengambilan ciri, dan klasifikasi hasil analisis. Setiap tahapan memiliki fungsi penting dalam menghasilkan representasi visual yang siap dianalisis oleh algoritma pembelajaran mesin. Proses pengolahan citra mencakup pengambilan gambar tanaman, peningkatan kualitas citra untuk memperjelas detail objek, pemisahan area daun dari latar belakang melalui segmentasi, pengambilan ciri warna dan tekstur melalui ekstraksi fitur, serta pengelompokan hasil analisis pada tahap klasifikasi untuk menentukan jenis penyakit daun tanaman [13].

Model klasifikasi berbasis pengolahan citra digital pada tanaman anggur dapat ditingkatkan keakuratannya dengan penerapan jaringan saraf konvolusional yang telah dilatih sebelumnya dan kemudian disesuaikan [14]. Salah satu arsitektur yang menunjukkan hasil sangat baik adalah varian *EfficientNet-B6*, dalam studi klasifikasi penyakit tanaman, pendekatan ini berhasil mencapai akurasi lebih dari 99% pada dataset dengan jumlah data yang besar [15].

B. Convolutional Neural Network (CNN)

Convolutional Neural Network adalah bentuk jaringan saraf tiruan yang dirancang khusus untuk menganalisis gambar melalui tahapan konvolusi, pooling, dan aktivasi agar dapat mengenali pola visual dari data input. CNN mampu mempelajari pola-citra kompleks (seperti tepi, bentuk, dan tekstur) tanpa harus merancang fitur manual sebelumnya, sehingga menjadi pilihan utama dalam klasifikasi penyakit pada daun tanaman [16].

C. EfficientNetB6

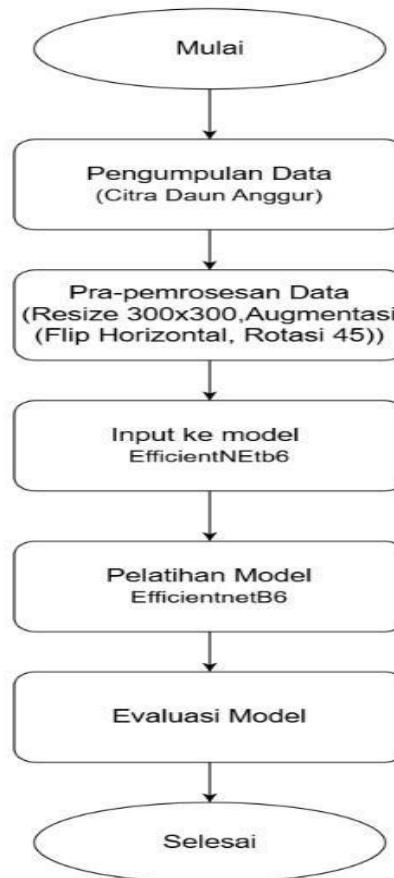
Arsitektur *EfficientNet* dikembangkan sebagai keluarga model CNN yang menggunakan metode *compound scaling*, yaitu penskalaan serempak pada kedalaman (*depth*), lebar (*width*), dan resolusi input jaringan agar memperoleh keseimbangan

antara akurasi dan efisiensi komputasi [17].

Versi-versi dari *EfficientNet* dinamai B0 hingga B7, di mana tiap peningkatan nomor (misalnya B5 sampai B6) merepresentasikan model yang lebih besar dengan jumlah parameter dan FLOPs (operasi *floating-point*) yang meningkat tetapi umumnya juga akurasi yang lebih tinggi [18].

III. METODOLOGI PENELITIAN

Diagram Alur Penelitian



Gbr. 1. Diagram Alur Penelitian

Tahapan awal metodologi meliputi pengumpulan dataset citra daun anggur dari sumber publik, diikuti oleh proses pra-pemrosesan yang mencakup penyesuaian ukuran citra serta penerapan augmentasi data untuk meningkatkan kesiapan dan keragaman data sebelum pelatihan model. Citra hasil prapemrosesan kemudian diinput ke dalam model *EfficientNetB6* untuk pelatihan klasifikasi penyakit daun. Evaluasi model dilaksanakan setelah proses pelatihan dengan menggunakan metrik kinerja, yaitu *accuracy*, *precision*, *recall*, dan *f1-score*, yang berfungsi untuk menguji keandalan model dalam mengenali masing-masing kelas penyakit daun anggur secara akurat.

A. Pengumpulan Data

Penelitian ini menggunakan sumber data dari dataset publik *Grape400* yang tersedia pada platform Kaggle. Dataset tersebut terdiri atas empat jenis citra daun anggur yang mewakili kategori *Black Rot*, *Black Measles*, *Leaf Blight*, dan *Healthy Leaves*. Setiap kategori memiliki jumlah gambar yang seimbang sehingga mendukung proses pelatihan model secara stabil serta mengurangi potensi ketidakseimbangan kelas. Seluruh data diperoleh dan diolah menggunakan layanan *Google Colab*, yang menyediakan lingkungan komputasi

berbasis GPU untuk mempercepat proses pelatihan model *deep learning*. Setiap citra berformat RGB dengan resolusi bervariasi sesuai sumber aslinya, kemudian seluruh gambar dimanfaatkan sebagai data masukan pada tahap pra-pemrosesan.

B. Pra-Pemrosesan

Pra-pemrosesan data dilakukan untuk menyamakan ukuran citra dan memperbanyak variasi data pelatihan. Setiap citra diubah ukurannya menjadi 300×300 piksel menggunakan metode interpolasi INTER_AREA agar citra memiliki resolusi yang seragam. Langkah berikutnya melibatkan penerapan teknik augmentasi data yang bertujuan meningkatkan ketahanan model terhadap perbedaan bentuk dan orientasi citra, sehingga kemampuan generalisasi dapat lebih baik. Proses augmentasi dilakukan dengan transformasi seperti pembalikan horizontal (*horizontal flip*) serta rotasi sebesar 45° guna menambah variasi sudut pengambilan gambar. Implementasi tahap ini memanfaatkan pustaka *OpenCV* dan *NumPy*, di mana setiap gambar menghasilkan tiga versi, yaitu gambar asli (*original*), hasil *flip*, dan hasil rotasi, sehingga total dataset bertambah sekitar tiga kali dari jumlah awalnya.

C. Pengembangan Model

Setelah tahap pra-pemrosesan selesai, seluruh citra hasil augmentasi dimasukkan ke dalam model *EfficientNetB6*, yaitu arsitektur *Convolutional Neural Network* (CNN) modern yang dirancang untuk mengoptimalkan keseimbangan antara kedalaman, lebar, dan resolusi jaringan melalui prinsip *compound scaling*. Model ini menggunakan bobot awal (*pre-trained weights*) dari dataset ImageNet sebagai dasar pembelajaran, kemudian dimodifikasi pada bagian *fully connected layer* agar sesuai dengan jumlah kelas penyakit daun anggur yang diklasifikasikan dalam penelitian ini. Arsitektur bagian kepala model dibangun melalui sejumlah lapisan utama yang meliputi *Global Average Pooling*, *Dense 256* dengan aktivasi *ReLU*, *Dropout 0,5*, *Dense 128* dengan aktivasi *ReLU*, serta lapisan keluaran *Softmax*. Model dilatih menggunakan *optimizer Adam* dengan *learning rate* sebesar 1×10^{-4} , sehingga diperoleh keseimbangan antara kecepatan konvergensi dan stabilitas selama proses pelatihan.

D. Evaluasi Model

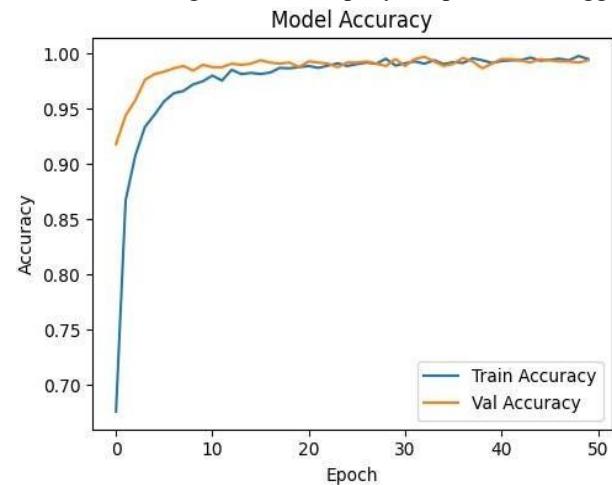
Tahap evaluasi dilakukan setelah proses pelatihan model selesai untuk menilai performa sistem klasifikasi penyakit daun anggur yang telah dikembangkan. Tahap evaluasi memanfaatkan data uji yang tidak digunakan selama proses pelatihan maupun validasi, sehingga hasil evaluasi mampu menggambarkan sejauh mana model dapat melakukan generalisasi terhadap data baru. Beberapa metrik evaluasi, meliputi *accuracy*, *precision*, *recall*, dan *f1-score*, diterapkan untuk menilai performa model, di mana masing-masing metrik memberikan perspektif terkait tingkat akurasi, sensitivitas, dan keseimbangan pada proses klasifikasi multi-kelas.

IV. HASIL DAN PEMBAHASAN

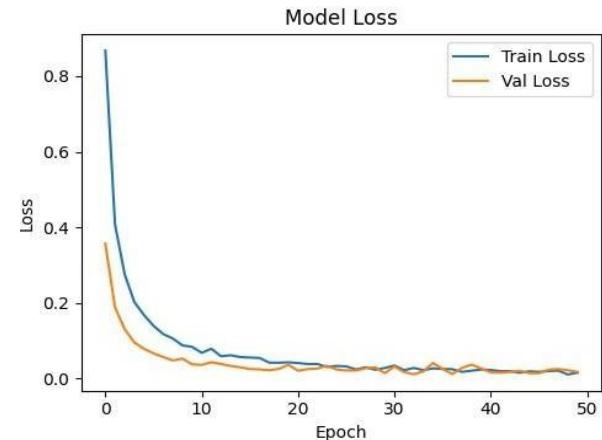
A. Hasil Training Model

Pelatihan model dilakukan sebanyak 50 epoch menggunakan arsitektur EfficientNetB6 sebagai inti sistem klasifikasi penyakit daun anggur. Perkembangan performa model selama proses pelatihan dapat diamati melalui visualisasi *accuracy* dan *loss* pada Gambar 2 dan Gambar 3. Berdasarkan grafik tersebut, model menunjukkan tren peningkatan kinerja yang stabil dan

signifikan seiring dengan bertambahnya *epoch* pelatihan. *accuracy* pada data latih meningkat secara bertahap dan stabil, mencapai 99% pada akhir pelatihan dengan nilai *loss* yang sangat rendah, yaitu 0,0354. Sementara itu, akurasi pada data validasi tercatat mencapai 98,75%, dengan nilai *loss* 0,0354, yang menunjukkan bahwa model belajar dengan baik dan dapat menggeneralisasi pada data yang belum dilihat sebelumnya. Grafik yang menunjukkan perubahan *accuracy* dan *loss* selama pelatihan memperlihatkan bahwa model mampu menjaga kestabilan antara data latih dan validasi, tanpa adanya indikasi *overfitting* yang signifikan. Penurunan *loss* yang konsisten pada kedua dataset (latih dan validasi) menggambarkan bahwa model tidak hanya menguasai data latih, tetapi juga berhasil mempelajari pola yang dapat diterapkan pada data yang tidak terlihat sebelumnya. Hal ini menunjukkan bahwa model *EfficientNetB6* dapat melakukan ekstraksi fitur yang efisien dan efektif untuk tugas klasifikasi penyakit pada daun anggur.



Gbr. 2. Grafik history accuracy pelatihan model



Gbr. 3. Grafik history loss pelatihan model

B. Evaluasi Model

Pada proses pengujian dan penilaian performa model, digunakan data uji yang tidak dilibatkan dalam pelatihan untuk mengukur sejauh mana model mampu melakukan generalisasi. Dari hasil evaluasi diperoleh bahwa model mencapai akurasi keseluruhan sebesar 0,988, yang menunjukkan tingkat keandalan tinggi dengan konsistensi antara metrik rata-rata makro dan rata-rata tertimbang, sebagaimana terlihat pada Tabel 1. Pada evaluasi tiap kelas, kategori *HealthyGrapes* terdeteksi dengan sempurna, ditandai dengan nilai *precision*, *recall*, dan *f1-score* masing-masing mencapai 1,000.

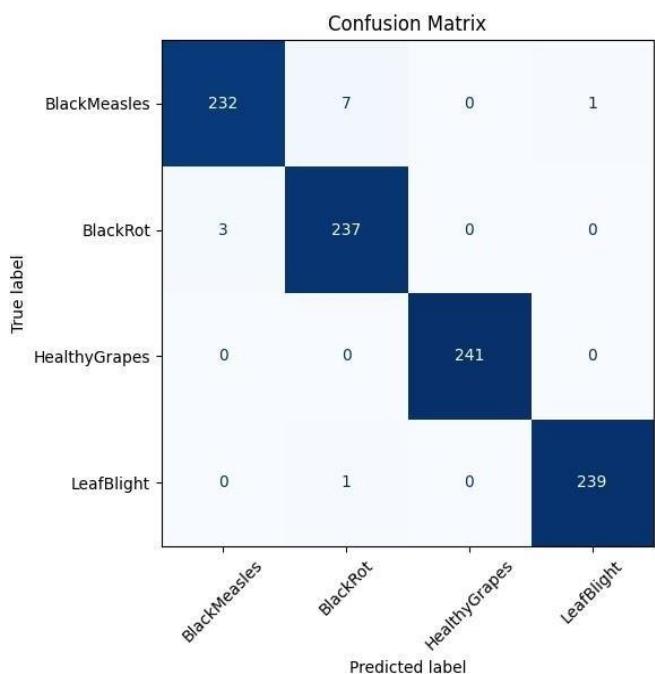
Sedangkan untuk kelas *LeafBlight*, performanya juga sangat baik dengan nilai *precision* 0,996, *recall* 0,996, dan *f1-score* 0,996. Adapun kelas *BlackMeasles* dan *BlackRot* sama-sama memperoleh *f1-score* sebesar 0,977, dengan perbedaan kecil antara *precision* dan *recall*, yang menandakan tingkat keseimbangan deteksi yang optimal pada kedua kelas tersebut.

TABEL 1

KLASIFIKASI MODEL EFFICIENTNETB6

Kelas	Precision	Recall	F1-Score	Support
BlackMeasles	0,987	0,967	0,977	240
BlackRot	0,967	0,988	0,977	240
HealthyGrapes	1,000	1,000	1,000	241
LeafBlight	0,996	0,996	0,996	240
accuracy			0,988	961
macro avg	0,988	0,988	0,987	961
weighted avg	0,988	0,988	0,988	961

Struktur kesalahan yang mendasari metrik tersebut tampak pada Gambar 4, di mana diagonal *confusion matrix* mendominasi dan kesalahan terlokalisasi terutama pada pasangan *BlackMeasles* dan *BlackRot*. Secara spesifik, 232 dari 240 sampel *BlackMeasles* dan 237 dari 240 sampel *BlackRot* diprediksi benar, sementara 7 sampel *BlackMeasles* terprediksi sebagai *BlackRot* dan 3 sampel *BlackRot* terprediksi sebagai *BlackMeasles*; *HealthyGrapes* terklasifikasi tepat seluruhnya 241 dari 241 sampel dan *LeafBlight* hanya menyisakan satu kesalahan. Keterkaitan antara ringkasan metrik pada Tabel 1 dan pola pada Gambar 4 menegaskan kemampuan generalisasi *EfficientNetB6* yang kuat pada empat kelas target, dengan separabilitas kelas sehat yang sangat tinggi serta distribusi kesalahan yang kecil dan spesifik sehingga model layak digunakan sebagai basis sistem bantu keputusan deteksi penyakit daun anggur berbasis citra.



Gbr. 4. Hasil Confusion Matrix

V. KESIMPULAN

Penelitian ini berhasil merancang dan mengevaluasi model klasifikasi penyakit daun anggur dengan empat kelas, yang berbasis pada arsitektur *Convolutional Neural Network EfficientNetB6* menggunakan skema pelatihan sebanyak 50 *epoch*. Sepanjang pelatihan, kurva *accuracy* dan *loss* pada data latih serta validasi menunjukkan tren yang selaras dan stabil, menandakan proses pembelajaran yang efektif tanpa indikasi *overfitting*. Pada pengujian terpisah, model mencapai akurasi keseluruhan 0,988, dengan kinerja per kelas yang sangat baik: *HealthyGrapes* teridentifikasi sempurna, *LeafBlight* mendekati sempurna, sedangkan *BlackMeasles* dan *BlackRot* masing-masing mempertahankan *f1-score* 0,977. Temuan ini menunjukkan bahwa *EfficientNetB6* mampu mengekstraksi fitur morfologis dan tekstural daun anggur yang relevan untuk membedakan kondisi sehat dan bergejala serta memisahkan variasi gejala antarkelas penyakit.

Secara praktis, rancangan ini layak diposisikan sebagai fondasi sistem bantu keputusan deteksi penyakit daun anggur berbasis citra, khususnya untuk skenario penyaringan awal yang menuntut sensitivitas dan spesifisitas tinggi. Untuk mendorong kinerja ke batas atas, pengembangan berikutnya disarankan memperkaya keragaman data melalui penambahan variasi *kultivar* daun anggur, tingkat keparahan, dan kondisi pencahaayaan, menerapkan *fine-tuning* bertahap pada blok atas *EfficientNetB6* dengan laju belajar kecil, memanfaatkan metode penjelasan seperti Grad-CAM untuk audit visual area perhatian model, serta melakukan kalibrasi probabilitas agar nilai keyakinan prediksi lebih reliabel pada konteks operasional.

UCAPAN TERIMA KASIH

Penulis menyampaikan apresiasi yang setulus-tulusnya kepada rekan-rekan yang telah berkolaborasi dalam setiap tahapan penelitian, mulai dari perumusan metodologi, pengumpulan serta pengolahan data citra daun anggur, hingga analisis performa model klasifikasi berbasis *EfficientNetB6*. Kontribusi berupa dukungan dan kerja sama dari berbagai pihak menjadi faktor yang berpengaruh terhadap terselesaikannya penelitian ini dengan baik. Hasil penelitian diharapkan mampu memberikan nilai tambah bagi pengembangan sistem pengenalan pola berbasis kecerdasan buatan yang berorientasi pada analisis dan pemantauan kesehatan tanaman. Selain itu, penelitian ini diharapkan dapat menjadi pijakan bagi riset lanjutan yang lebih luas dan mendalam pada bidang terkait.

REFERENSI

- [1] A. Khadatkar *et al.*, “A comprehensive review on grapes (*Vitis spp.*) cultivation and its crop management,” *Discov. Agric.*, vol. 3, no. 1, 2025, doi: 10.1007/s44279-025-00162-2.
- [2] X. Xie, Y. Ma, B. Liu, J. He, S. Li, and H. Wang, “A Deep-Learning-Based Real-Time Detector for Grape Leaf Diseases Using Improved Convolutional Neural Networks,” *Front. Plant Sci.*, vol. 11, no. June, pp. 1–14, 2020, doi: 10.3389/fpls.2020.00751.
- [3] P. G. Aher, V. Sabnis, and J. K. Jain, “Deep learning for grape leaf disease detection: A review,” *Multidiscip. Rev.*, vol. 8, no. 11, pp. 1–14, 2025, doi: 10.31893/multirev.2025364.
- [4] F. Atesoglu and H. Bingol, “The Detection and Classification of Grape Leaf Diseases with an Improved Hybrid Model Based on Feature Engineering and AI,” *AgriEngineering*, vol. 7, no. 7, pp. 1–13, 2025, doi: 10.3390/agriengineering7070228.
- [5] S. A. Wagle, R. Harikrishnan, S. H. M. Ali, and M. Faseehuddin, “Classification of plant leaves using new compact convolutional neural network models,” *Plants*, vol. 11, no. 1, pp. 1–25, 2022, doi: 10.3390/plants11010024.
- [6] M. P. Mathew, “A comparative deep learning framework for grape leaf disease classification using EfficientNetB0, InceptionV3, and Xception,” *Discov. Appl. Sci.*, vol. 7, no. 10, 2025, doi: 10.1007/s42452-025-07457-5.

- [7] M. A. Hasan, Y. Riyanto, and D. Riana, "Grape leaf image disease classification using CNN-VGG16 model," *J. Teknol. dan Sist. Komput.*, vol. 9, no. 4, pp. 218–223, 2021, doi: 10.14710/jtsiskom.2021.14013.
- [8] 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, 2025, doi: 10.52465/joscev.v6i1.507.
- [9] S. V. Sinha and B. M. Patil, "INTELLIGENT SYSTEMS AND APPLICATIONS IN ENGINEERING Comparative Analysis of CNN, EFFICIENTNET and RESNET for Grape Disease Prediction : A Deep Learning Approach," 2024.
- [10] B. Liu, Z. Ding, L. Tian, D. He, S. Li, and H. Wang, "Grape Leaf Disease Identification Using Improved Deep Convolutional Neural Networks," *Front. Plant Sci.*, vol. 11, no. July, pp. 1–14, 2020, doi: 10.3389/fpls.2020.01082.
- [11] M. A. Hasan, D. Riana, S. Swasono, and A. Priyatna, "Identification of Grape Leaf Diseases Using Convolutional Neural Network Identification of Grape Leaf Diseases Using Convolutional Neural Network," 2020, doi: 10.1088/1742-6596/1641/1/012007.
- [12] Barbedo and J. G. Arnal, "Digital Image Processing for Detecting and Classifying Plant Diseases," *Circ. Comput. Sci.*, vol. 2, no. 11, pp. 1–7, 2017, doi: 10.22632/ccs-2017-252-66.
- [13] J. A. Gómez-Camperos, H. Y. Jaramillo, and G. Guerrero-Gómez, "Digital image processing techniques for detection of pests and diseases in crops: a review.,," *Ing. y Compet.*, vol. 24, no. 1, pp. 1–17, 2022, doi: 10.25100/iyc.24i1.10973.
- [14] 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, 2024, doi: 10.1007/s41348-024-00896-z.
- [15] V. Terisia *et al.*, "Comparison of EfficientNet B5-B6 for Detection of 29 Diseases of Fruit Plants," *Sainteks*, vol. 20, no. 2, pp. 107–118, 2023, doi: 10.30595/sainteks.v20i2.18691.
- [16] J. Lu, L. Tan, and H. Jiang, "Review on convolutional neural network (CNN) applied to plant leaf disease classification," *Agric.*, vol. 11, no. 8, pp. 1–18, 2021, doi: 10.3390/agriculture11080707.
- [17] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, 2019.
- [18] R. Akinca, H. Firat, and M. E. Asker, "Automated Fault Classification in Solar Panels Using Transfer Learning with EfficientNet and ResNet Models," *Eur. J. Tech.*, vol. 14, no. 2, pp. 164–173, 2024, [Online]. Available: <https://dergipark.org.tr/en/pub/ejt/issue/89949/1533783>