

EVALUASI KLASIFIKASI PENYAKIT DAUN TEH MENGGUNAKAN TRANSFER LEARNING EFFICIENTNETB0

Santowi Azis¹, Bambang Irawan²

^{1,2} Universitas Muhadi Setiabudi, Jl. Pangeran Diponogoro, KM 2 Pesantunan, Wanasari, Kabupaten Brebes, Jawa Tengah 52221, Telp (0283) 6199000

Keywords:

Penyakit Daun Teh,
Convolutional Neural
Network, EfficientNetB0,
Transfer Learning,
Klasifikasi Citra

Correspondent Email:

azissantowi@gmail.com

Abstrak: Penelitian ini mengevaluasi performa model EfficientNetB0 berbasis transfer learning untuk deteksi dini penyakit daun teh. Dataset Tea Leaf Disease yang tersedia secara publik digunakan, terdiri dari 5.867 gambar daun teh dengan enam kelas, yaitu algal spot, brown blight, gray blight, healthy, helopeltis, dan red spot. Dataset dibagi menjadi data latih (70%), validasi (15%), dan uji (15%). Model dilatih selama 30 epoch dengan laju pembelajaran 1×10^{-4} , kemudian dilakukan fine-tuning selama 15 epoch tambahan menggunakan laju pembelajaran 1×10^{-5} disertai augmentasi data yang intensif. Hasil pengujian pada data uji menunjukkan akurasi sebesar 97%, dengan nilai macro-averaged precision, recall, dan F1-score masing-masing mencapai 0,97. Analisis confusion matrix mengindikasikan tingkat kesalahan klasifikasi yang rendah, meskipun masih terjadi kesalahan pada kelas-kelas yang memiliki kemiripan visual tinggi, seperti brown blight dengan gray blight serta helopeltis dengan healthy. Hasil ini menunjukkan bahwa EfficientNetB0 memiliki akurasi dan efisiensi yang tinggi, sehingga berpotensi untuk diimplementasikan pada aplikasi mobile sebagai sistem pendukung deteksi dini penyakit daun teh bagi petani.



Copyright © [JITET](#) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract: This study evaluates the performance of a transfer learning-based EfficientNetB0 model for the early detection of tea leaf diseases. The publicly available Tea Leaf Disease dataset, consisting of 5,867 images across six classes (algal spot, brown blight, gray blight, healthy, helopeltis, and red spot), was used. The dataset was split into training (70%), validation (15%), and test (15%) sets. The model was initially trained for 30 epochs with a learning rate of 1×10^{-4} , followed by fine-tuning for an additional 15 epochs using a reduced learning rate of 1×10^{-5} and intensive data augmentation. Evaluation on the test set yielded an accuracy of 97%, with macro-averaged precision, recall, and F1-score each reaching 0.97. Analysis of the confusion matrix revealed minimal misclassifications, primarily occurring between visually similar classes, such as brown blight and gray blight, as well as helopeltis and healthy. These results demonstrate the high accuracy and efficiency of EfficientNetB0, highlighting its potential for deployment in mobile applications as a practical early detection tool to support tea farmers.

1. PENDAHULUAN

Tanaman teh (*Camellia sinensis*) merupakan salah satu komoditas perkebunan penting yang berkontribusi terhadap sektor agribisnis dan ekonomi, khususnya di negara berkembang seperti Indonesia. Namun, produktivitas tanaman teh sangat rentan terhadap berbagai penyakit daun, antara lain *algal spot*, *brown blight*, *gray blight*, *red spot*, serta serangan hama *helopeltis*, yang dapat menyebabkan penurunan kualitas dan kuantitas hasil panen secara signifikan apabila tidak ditangani sejak dini [1]. Pada praktiknya, proses identifikasi penyakit daun teh masih banyak dilakukan secara manual oleh petani atau tenaga ahli di lapangan. Metode ini memiliki keterbatasan, terutama pada area perkebunan yang luas, karena bersifat subjektif, memerlukan waktu yang lama, serta berpotensi menghasilkan kesalahan diagnosis akibat kemiripan visual antar penyakit [2]. Kondisi tersebut mendorong perlunya sistem deteksi otomatis yang akurat dan efisien.

Perkembangan *deep learning*, khususnya Convolutional Neural Network (CNN), telah menunjukkan kinerja yang sangat baik dalam berbagai aplikasi pengolahan citra, termasuk deteksi penyakit tanaman. Studi sebelumnya melaporkan bahwa CNN mampu mengenali pola visual kompleks pada daun tanaman dengan tingkat akurasi yang tinggi dibandingkan metode konvensional berbasis fitur manual [3]. Berbagai arsitektur CNN telah diterapkan dalam klasifikasi penyakit daun teh, seperti ResNet, MobileNet, DenseNet, hingga EfficientNet, dengan akurasi yang dilaporkan berkisar antara 94% hingga 98% [4]. Selain itu, pendekatan berbasis *remote sensing* dan *object detection* seperti YOLO juga mulai dikembangkan untuk skenario lapangan berskala besar [5]. Pendekatan pembelajaran mesin juga telah banyak diterapkan dalam berbagai bidang penelitian di JITET, baik pada data citra maupun teks, dan terbukti mampu meningkatkan akurasi analisis dibandingkan metode konvensional [6].

Meskipun demikian, sebagian besar penelitian sebelumnya masih berfokus pada

peningkatan akurasi melalui model kompleks atau *ensemble*, yang berdampak pada tingginya kebutuhan komputasi. Oleh karena itu, diperlukan pendekatan yang mampu menjaga keseimbangan antara performa dan efisiensi komputasi, terutama untuk implementasi pada perangkat bergerak.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan penggunaan EfficientNetB0 dengan strategi *transfer learning* dan *fine-tuning* bertahap untuk mengklasifikasikan enam kondisi daun teh. Kontribusi utama penelitian ini adalah optimalisasi pelatihan dua tahap yang menghasilkan performa generalisasi tinggi pada data uji, sekaligus mempertahankan efisiensi model untuk aplikasi praktis.

2. TINJAUAN PUSTAKA

2.1. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu arsitektur *deep learning* yang paling luas digunakan untuk pemrosesan citra. CNN bekerja melalui lapisan konvolusi, *pooling*, dan *fully connected layer* yang mampu mengekstraksi fitur citra secara hierarkis dari pola sederhana hingga pola kompleks [7]. Pendekatan ini telah terbukti unggul dibandingkan metode tradisional berbasis ekstraksi fitur manual dalam mengenali karakteristik visual yang kompleks [3].

Dalam konteks deteksi penyakit tanaman, CNN dapat mengidentifikasi pola warna, bentuk, dan tekstur daun dengan tingkat akurasi tinggi. Beberapa penelitian sebelumnya menunjukkan bahwa penerapan CNN pada citra daun mampu memberikan hasil yang lebih konsisten dibandingkan dengan metode pengolahan citra konvensional [8]. CNN juga memungkinkan proses pembelajaran representasi visual secara otomatis, yang menjadikannya cocok untuk permasalahan dengan tingkat variabilitas visual tinggi, seperti klasifikasi penyakit daun teh.

2.2. Arsitektur EfficientNet

EfficientNet merupakan pengembangan dari CNN yang memperkenalkan pendekatan *compound scaling*, yaitu strategi yang menyeimbangkan kedalaman (*depth*), lebar (*width*), dan resolusi input secara proporsional

[8]. Pendekatan ini menghasilkan model dengan efisiensi tinggi, di mana peningkatan akurasi tidak selalu disertai dengan peningkatan kompleksitas komputasi. Beberapa penelitian terkini menunjukkan bahwa EfficientNet memiliki performa unggul dalam klasifikasi citra pertanian. Raza [9] menunjukkan bahwa EfficientNetB0 dapat digunakan untuk deteksi penyakit daun teh dengan tingkat akurasi yang kompetitif.

Sementara itu, Islam et al. [10] mengembangkan model *lightweight deep learning* berbasis EfficientNet yang lebih hemat komputasi namun tetap menghasilkan akurasi tinggi. Ozturk et al. [11] juga membuktikan bahwa kombinasi EfficientNet dengan metode *ensemble* dapat meningkatkan stabilitas hasil klasifikasi pada dataset tanaman teh.

Pendekatan arsitektur yang efisien ini sangat relevan untuk penelitian yang membutuhkan keseimbangan antara akurasi dan efisiensi, terutama ketika model diterapkan pada perangkat bergerak atau sistem berbasis *Internet of Things (IoT)*.

2.3. Transfer Learning dan Fine-Tuning

Pendekatan *transfer learning* menjadi strategi populer dalam pengembangan model *deep learning* karena memungkinkan pemanfaatan model *pre-trained* yang telah dilatih pada dataset besar seperti ImageNet [12]. Model tersebut kemudian disesuaikan untuk domain baru melalui proses *fine-tuning* menggunakan dataset spesifik, seperti citra daun teh. Proses ini mempercepat pelatihan dan meningkatkan performa karena model *pre-trained* telah memahami representasi umum dari pola visual alami. Teknik ini sangat efektif untuk dataset yang terbatas jumlahnya, karena bobot awal dari model dasar sudah membawa pengetahuan visual umum. Beberapa studi sebelumnya [13], [14] juga menegaskan bahwa *transfer learning* mampu meningkatkan akurasi model dengan waktu pelatihan yang lebih singkat.

Dalam penelitian ini, strategi *fine-tuning* dua tahap digunakan untuk mengoptimalkan pembelajaran model. Tahap pertama dilakukan dengan membekukan lapisan dasar dan melatih lapisan atas, kemudian pada tahap kedua sebagian lapisan dasar dibuka agar model dapat menyesuaikan diri lebih baik terhadap karakteristik penyakit daun teh.

2.4. Penelitian Terkait Klasifikasi Penyakit Daun Teh

Beberapa penelitian terdahulu telah menyoroti keberhasilan penggunaan CNN dan turunannya dalam mengklasifikasikan penyakit daun teh. Rahat et al. [1] menerapkan CNN dan pengolahan citra untuk mendeteksi penyakit daun teh dan memperoleh hasil akurasi yang tinggi. Wu et al. [2] menggunakan pendekatan *Attention CNN* yang menggabungkan fitur konvolusional dan fitur buatan tangan untuk meningkatkan kemampuan model dalam membedakan kelas penyakit dengan kemiripan visual tinggi.

Ozturk et al. [4] mengusulkan metode *ensemble deep learning* yang robust dan dapat diinterpretasikan untuk klasifikasi penyakit daun teh, sedangkan Bao et al. [5] mengembangkan sistem deteksi penyakit berbasis *remote sensing* menggunakan model YOLO untuk pengamatan lapangan berskala besar. Selain itu, Li et al. [15] memodifikasi arsitektur MobileNetV3 agar lebih efisien pada citra daun teh dan sama dengan hasil akurasi yang kompetitif.

Studi lain oleh Yang et al. [14] dan Lien [13] mengusulkan model *lightweight CNN* serta *wavelet-CNN* untuk mendukung penerapan sistem cerdas pada perangkat dengan sumber daya terbatas. Hasil-hasil tersebut menunjukkan bahwa pengembangan model yang ringan namun akurat menjadi tren penting dalam penelitian terbaru. Penelitian ini mengacu pada tren tersebut dengan menerapkan EfficientNetB0 yang dikenal efisien secara komputasi namun tetap memiliki akurasi tinggi.

2.5. Ringkasan Tinjauan Pustaka

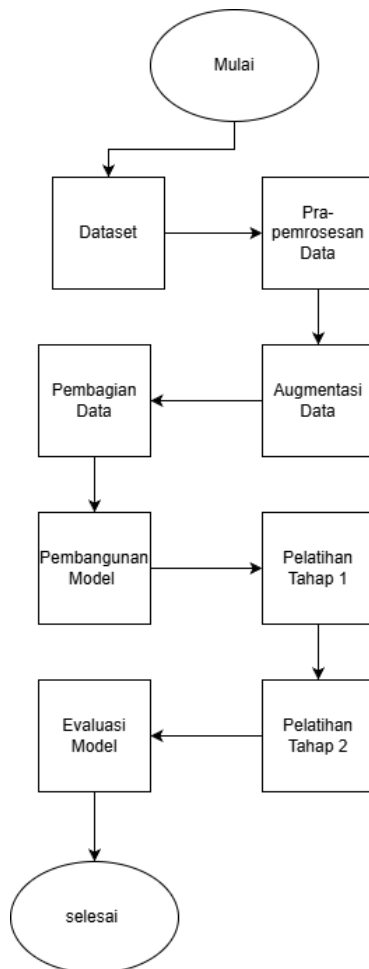
Dari berbagai penelitian yang telah dibahas, dapat disimpulkan bahwa arsitektur CNN memiliki kemampuan yang sangat baik dalam mengenali pola visual kompleks, sementara EfficientNet memberikan peningkatan signifikan dalam hal efisiensi dan akurasi. Penerapan *transfer learning* dan *fine-tuning* semakin memperkuat kinerja model, terutama pada dataset berukuran kecil seperti citra daun teh.

Dengan mempertimbangkan hasil-hasil penelitian sebelumnya pemanfaatan EfficientNetB0 dalam penelitian ini diharapkan dapat memberikan keseimbangan optimal antara performa dan efisiensi komputasi. Pendekatan ini sangat potensial untuk

mendukung sistem deteksi dini penyakit daun teh berbasis perangkat bergerak yang praktis digunakan oleh petani di lapangan.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen berbasis deep learning untuk mengevaluasi kinerja model *transfer learning* EfficientNetB0 dalam mendeteksi dan mengklasifikasikan penyakit daun tanaman teh. Pendekatan *transfer learning* dengan EfficientNetB0 dipilih karena telah terbukti efektif dalam berbagai studi klasifikasi citra agronomi [1]. Seluruh tahapan penelitian dirancang secara sistematis agar eksperimen dapat direproduksi dan hasil evaluasi dapat dianalisis secara objektif.



Gambar 3.1 Rancangan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen berbasis deep learning untuk mengevaluasi kinerja model *transfer learning* EfficientNetB0 dalam

mendeteksi dan mengklasifikasikan penyakit daun tanaman teh. Pendekatan *transfer learning* dengan EfficientNetB0 dipilih karena telah terbukti efektif dalam berbagai studi klasifikasi citra agronomi [1]. Seluruh tahapan penelitian dirancang secara sistematis agar eksperimen dapat direproduksi dan hasil evaluasi dapat dianalisis secara objektif.

3.1. Dataset dan pengumpulan data

Penelitian ini menggunakan dataset Tea Leaf Disease yang diperoleh dari platform Kaggle dan telah digunakan secara luas pada penelitian sebelumnya, sehingga validitasnya dapat dipertanggungjawabkan [17]. Dataset tersebut terdiri dari 5.867 citra daun teh yang terbagi ke dalam enam kelas kondisi, meliputi *algal spot*, *brown blight*, *gray blight*, *healthy*, *helopeltis*, dan *red spot*. Dataset ini dipilih karena merepresentasikan variasi visual penyakit daun teh yang umum ditemukan di lapangan.

Tabel 3.1 jumlah dataset

No	Nama label	Jumlah citra
1	Algal_spot	1000
2	Brown_blight	867
3	Gray_blight	1000
4	Healthy	1000
5	Helopeltis	1000
6	Red_spot	1000
Total		5867



Red_spot



helopeltis



Healthy



Gray_blight



Brown_blight



Algal_spot

Gambar 3.2 Contoh dataset

3.2. Pembagian data

Dataset dibagi menjadi tiga subset, yaitu data latih sebanyak 4.106 citra (70%), data validasi sebanyak 880 citra (15%), dan data uji sebanyak 881 citra (15%). Pembagian data dilakukan secara acak (*random shuffle*) untuk memastikan distribusi data yang seimbang dan menghindari bias selama proses pelatihan dan evaluasi model.

3.3. Augmentasi Data

Seluruh citra dilakukan pra-pemrosesan dengan menyesuaikan ukuran input menjadi 224×224 piksel, sesuai dengan spesifikasi input EfficientNetB0. Normalisasi nilai piksel dilakukan menggunakan fungsi preprocess input dari EfficientNet. Untuk meningkatkan variasi data latih dan mengurangi risiko *overfitting*, diterapkan teknik augmentasi data pada data latih yang meliputi rotasi, *zooming*, pergeseran horizontal dan vertikal, serta *horizontal flipping*. Data validasi dan data uji tidak dikenakan augmentasi agar mencerminkan kondisi data nyata.

3.4. Arsitektur Model

Model klasifikasi citra dibangun menggunakan EfficientNetB0 sebagai *base model* dengan bobot *pretrained* ImageNet dan tanpa lapisan klasifikasi awal (*include_top=False*). Lapisan ekstraksi fitur diikuti oleh Global Average Pooling, lapisan Dense dengan 512 neuron dan aktivasi ReLU, Dropout sebesar 0,5, serta lapisan keluaran Dense dengan aktivasi Softmax untuk mengklasifikasikan enam kelas penyakit daun teh.

3.5. Strategi pelatihan dan fine-tuning

Proses pelatihan dilakukan dalam dua tahap. Pada tahap pertama, seluruh lapisan *base model* dibekukan dan model dilatih selama 30 epoch dengan *learning rate* sebesar 1×10^{-4} . Pada tahap kedua, dilakukan fine-tuning bertahap dengan membuka sebagian lapisan *base model*, kemudian pelatihan dilanjutkan selama 15 epoch menggunakan *learning rate* yang lebih kecil, yaitu 1×10^{-5} . Proses pelatihan menggunakan *batch size* 16 serta didukung oleh *callback* EarlyStopping dan ReduceLROnPlateau.

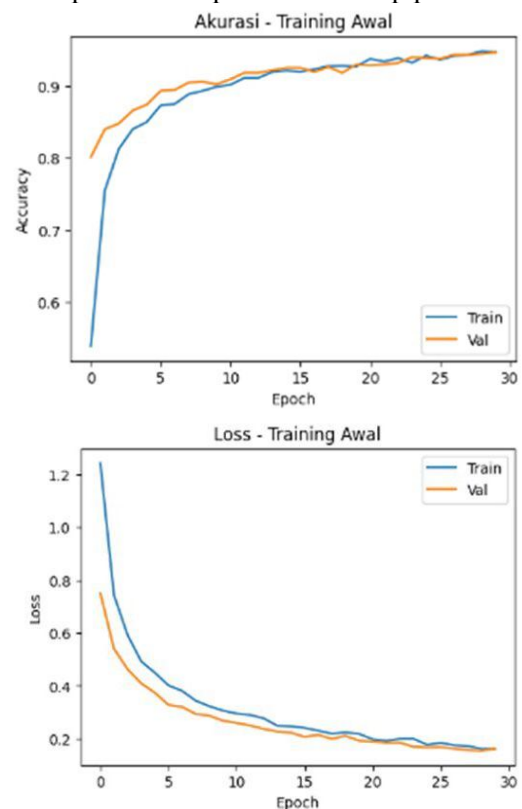
3.6. Evaluasi dan analisis

Evaluasi kinerja model dilakukan menggunakan data uji dengan metrik akurasi, presisi, recall, dan F1-score. Selain itu, confusion matrix digunakan untuk menganalisis

kesalahan klasifikasi antar kelas. Visualisasi kurva akurasi dan *loss* selama pelatihan disajikan untuk menilai stabilitas dan konvergensi model.

4. HASIL DAN PEMBAHASAN

Model EfficientNetB0 dilatih menggunakan pendekatan *transfer learning* dan *fine-tuning* dua tahap. Proses pelatihan menunjukkan konvergensi yang stabil, ditandai dengan peningkatan nilai akurasi dan penurunan nilai *loss* secara konsisten pada data latih dan data validasi. Hasil Kurva pelatihan menunjukkan konvergensi sangat baik tanpa *overfitting* signifikan. Akurasi *training* meningkat stabil hingga ~95%, sementara akurasi *validation* mencapai 94.66% pada akhir tahap pertama.



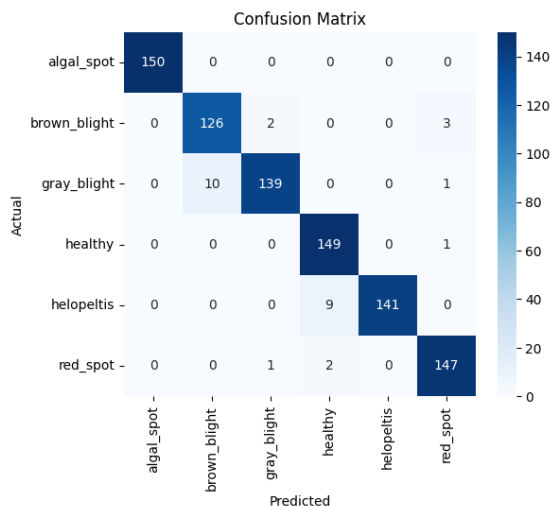
Gambar 4.1 Kurva Akurasi dan Loss Selama Proses Pelatihan

Evaluasi kinerja model dilakukan menggunakan data uji yang tidak terlibat dalam proses pelatihan. Hasil pengujian menunjukkan bahwa model mencapai akurasi sebesar 97%, yang menandakan performa klasifikasi yang sangat baik. Selain akurasi, nilai precision, recall, dan F1-score pada *macro average* masing-masing mencapai 0,97, yang menunjukkan keseimbangan performa antar kelas.

	precision	recall	f1-score	support
algal_spot	1.00	1.00	1.00	150
brown_blight	0.93	0.96	0.94	131
gray_blight	0.98	0.93	0.95	150
healthy	0.93	0.99	0.96	150
helopeltis	1.00	0.94	0.97	150
red_spot	0.97	0.98	0.97	150
accuracy			0.97	881
macro avg	0.97	0.97	0.97	881
weighted avg	0.97	0.97	0.97	881

Gambar 4.2 Hasil Classification Report pada Data Uji

Confusion matrix digunakan untuk menganalisis kesalahan klasifikasi antar kelas secara lebih rinci. Hasil analisis menunjukkan bahwa sebagian besar citra daun teh berhasil diklasifikasikan dengan benar. Kesalahan klasifikasi yang terjadi relatif kecil dan umumnya terjadi pada kelas yang memiliki kemiripan visual tinggi, seperti antara *brown blight* dan *gray blight*, serta antara *helopeltis* dan *healthy*. Kemiripan pola warna dan tekstur pada kelas-kelas tersebut menjadi faktor utama penyebab kesalahan prediksi.



Gambar 4.3 Confusion Matrix Hasil Klasifikasi Data Uji

Hasil penelitian menunjukkan bahwa strategi *fine-tuning* bertahap yang diterapkan mampu meningkatkan performa model dibandingkan pendekatan pelatihan satu tahap. Temuan penelitian ini sejalan dengan studi sebelumnya yang menerapkan EfficientNetB0 secara khusus pada deteksi penyakit daun teh, yang menunjukkan keseimbangan antara akurasi dan efisiensi komputasi[9].

Dibandingkan dengan penelitian sebelumnya yang melaporkan akurasi berkisar antara 94% hingga 96% pada arsitektur CNN serupa, adapun penelitian lain yang memanfaatkan arsitektur EfficientNetB0 untuk klasifikasi penyakit daun teh, seperti model modified EfficientNetB0 yang hanya mencapai akurasi sekitar 90-94% pada dataset serupa [10]), serta implementasi standalone EfficientNetB0 yang dilaporkan hanya 96% akurasi [11] model yang diusulkan dalam penelitian ini berhasil mencatat akurasi 97%. Peningkatan ini dapat diatribusikan pada optimalisasi hyperparameter, teknik augmentasi data yang lebih efektif, serta fine-tuning transfer learning yang lebih tepat, sehingga menunjukkan performa superior dan potensi aplikatif yang lebih tinggi dalam deteksi penyakit daun teh di lingkungan nyata.

Keunggulan utama model ini terletak pada penggunaan strategi *fine-tuning* bertahap dengan pengaturan *learning rate* yang berbeda. Pendekatan ini memungkinkan model mempertahankan fitur visual umum yang telah dipelajari dari dataset ImageNet, sekaligus menyesuaikan fitur tingkat tinggi yang lebih spesifik terhadap karakteristik penyakit daun teh. Selain itu, penerapan augmentasi data secara intensif turut berkontribusi dalam meningkatkan ketahanan model terhadap variasi citra lapangan.

Meskipun demikian, model masih menunjukkan keterbatasan dalam membedakan kelas dengan kemiripan visual yang tinggi. Hal ini mengindikasikan bahwa pada penelitian selanjutnya, peningkatan performa dapat dilakukan melalui penambahan mekanisme *attention*, penggunaan resolusi citra yang lebih tinggi, atau penggabungan fitur tekstur tambahan untuk meningkatkan diskriminasi antar kelas.

5. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model EfficientNetB0 yang diterapkan dengan pendekatan *transfer learning* dan strategi *fine-tuning* bertahap mampu mencapai akurasi pengujian sebesar 97% dalam mengklasifikasikan enam kondisi daun tanaman teh. Hasil tersebut menunjukkan bahwa model memiliki kemampuan generalisasi yang tinggi dengan efisiensi komputasi yang baik, sehingga

layak digunakan sebagai solusi deteksi dini penyakit daun teh, meskipun masih terdapat keterbatasan dalam membedakan kelas dengan tingkat kemiripan visual tertentu.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada tim Jurnal Informatika dan Teknik Elektro Terapan (JITET) Universitas Lampung atas template dan pedoman penulisan yang disediakan, serta kepada teman-teman yang sudah berkontribusi dalam penyelesaian artikel ini.

DAFTAR PUSTAKA

- [1] I. S. Rahat, H. Ghosh, S. Dara, and S. Kant, "Towards precision agriculture tea leaf disease detection using CNNs and image processing," *Sci. Rep.*, vol. 15, no. 1, 2025, doi: 10.1038/s41598-025-02378-0.
- [2] P. Wu, J. Liu, M. Jiang, L. Zhang, S. Ding, and K. Zhang, "Tea leaf disease recognition using attention convolutional neural network and handcrafted features," *Crop Prot.*, vol. 190, p. 107118, 2025, doi: 10.1016/j.cropro.2025.107118.
- [3] P. Bansal, Ranvijay, and M. Yadav, "Automatic detection of plant leaf diseases using deep learning," in *International Journal of Computing and Digital Systems*, 2023, pp. 901–910. doi: 10.12785/ijcds/130171.
- [4] O. Ozturk, B. Sarica, and D. Z. Seker, "Interpretable and Robust Ensemble Deep Learning Framework for Tea Leaf Disease Classification," *Horticulturae*, vol. 11, no. 4, p. 437, 2025, doi: 10.3390/horticulturae11040437.
- [5] W. Bao, Z. Zhu, G. Hu, X. Zhou, D. Zhang, and X. Yang, "UAV remote sensing detection of tea leaf blight based on DDMA-YOLO," *Comput. Electron. Agric.*, vol. 205, p. 107637, 2023, doi: 10.1016/j.compag.2023.107637.
- [6] D. Duei Putri, G. F. Nama, and W. E. Sulistiono, "Analisis Sentimen Kinerja Dewan Perwakilan Rakyat (DPR) Pada Twitter Menggunakan Metode Naive Bayes Classifier," *J. Inform. dan Tek. Elektro Terap.*, vol. 10, no. 1, 2022, doi: 10.23960/jitet.v10i1.2262.
- [7] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J. Big Data*, vol. 8, no. 1, p. 53, 2021, doi: 10.1186/s40537-021-00444-8.
- [8] J. A. Pandian, S. N. Nisha, K. Kanchanadevi, A. K. Pandey, and S. K. Rima, "Grey Blight Disease Detection on Tea Leaves Using Improved Deep Convolutional Neural Network," *Comput. Intell. Neurosci.*, vol. 2023, no. 1, 2023, doi: 10.1155/2023/7876302.
- [9] A. Raza, "Enhancing Tea Plant Health Through Machine Learning: EfficientNet-B0 for Tea Sickness Detection," *Int. J. Comput. Appl.*, vol. 186, no. 45, pp. 1–7, 2024, doi: 10.5120/ijca2024924092.
- [10] M. R. Islam *et al.*, "A Lightweight Deep Learning Model for Tea Leaf Disease Identification," *Mach. Learn. Knowl. Extr.*, vol. 7, no. 4, p. 123, 2025, doi: 10.3390/make7040123.
- [11] Ö. Öztürk, B. Sarica, and D. Z. Şeker, "Interpretable and Robust Ensemble Deep Learning Framework for Tea Leaf Disease Classification," *Horticulturae*, vol. 11, no. 4, p. 437, 2025, doi: 10.3390/horticulturae11040437.
- [12] 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.
- [13] Z. Xue, R. Xu, D. Bai, and H. Lin, "YOLO-Tea: A Tea Disease Detection Model Improved by YOLOv5," *Forests*, vol. 14, no. 2, p. 415, 2023, doi: 10.3390/f14020415.
- [14] B. Lien, "A Lightweight Deep Learning Model for Tea Leaf Disease Identification," *Machines*, no. 4, p. 123, 2025.
- [15] Y. Li *et al.*, "Tea leaf disease and insect identification based on improved MobileNetV3," *Front. Plant Sci.*, vol. 15, 2024, doi: 10.3389/fpls.2024.1459292.
- [16] J. Yang, G. J. Xu, M. D. Yang, and Z. P. Lin, "Lightweight wavelet-CNN tea leaf disease detection," *PLoS One*, vol. 20, no. 5 May, p. e0323322, 2025, doi: 10.1371/journal.pone.0323322.
- [17] Febrian abie pratama, Miftahus solihin, and Siti mujilahwati, "Deep Learning-Based CNN for Tea Leaf Disease Classification," *J. Artif. Intell. Eng. Appl.*, vol. 5, no. 1, pp. 1814–1822, 2025, doi: 10.59934/jaica.v5i1.1724.