

## Klasifikasi Penyakit Tanaman Anggur Menggunakan Adaptive Minimal Ensemble

Abdurrahman Al Hakim, Bima Ahmad Dionfaka, Chiristian Khosuma\*,  
Talitha Bertha Arvyandita, Fetty Tri Anggraeny

Universitas Pembangunan Nasional "Veteran" Jawa Timur

\*Penulis korespondensi. E-mail: 21081010169@student.upnjatim.ac.id

### ABSTRACT

Increasing agricultural productivity is highly dependent on the ability to detect plant diseases early. Grape crops, which have high economic value, often face threats from diseases such as downy mildew, powdery mildew, black rot, and botrytis bunch rot. Traditional disease detection methods, such as visual inspection, have several limitations, including dependence on human expertise, inefficiency for large agricultural areas, and inaccuracy under variable field conditions. In addition, diseases that have similar symptoms and image quality that is affected by lighting or viewing angle often complicate the detection process. To address these issues, this study developed the Adaptive Minimal Ensemble (AME) method, a machine learning approach based on the EfficientNet architecture. AME adaptively combines the strengths of two best-in-class models to improve detection accuracy while reducing the need for computational resources compared to traditional ensemble methods. The research process involved training the model on two types of datasets: the Original dataset (4062 images) and the Augmented dataset (4639 images). The data were split for training (60%), validation (20%), and testing (20%) using an end-to-end and fine-tuning scheme. The results show that AME produces superior performance compared to the EfficientNet B7 and EfficientNet B0 models individually. On the Augmented dataset, AME achieved the highest test accuracy of 99.35% with the lowest test loss of 0.0238. Meanwhile, on the Original dataset, AME recorded an accuracy of 98.32%. This performance was achieved using only around 10 million parameters, much more efficient than EfficientNet B7 which has 66 million parameters.

### Keywords

Adaptive Minimal Ensemble,  
Plant Disease, Classification,  
Machine Learning,  
Image Processing.

### ABSTRAK

Peningkatan produktivitas pertanian sangat bergantung pada kemampuan mendeteksi penyakit tanaman secara dini. Tanaman anggur, yang memiliki nilai ekonomi tinggi, sering menghadapi ancaman penyakit seperti downy mildew, powdery mildew, black rot, dan botrytis bunch rot. Metode deteksi penyakit tradisional, seperti inspeksi visual, memiliki beberapa keterbatasan, termasuk ketergantungan pada keahlian manusia, ketidakefisienan untuk area pertanian yang luas, dan ketidakakuratan dalam kondisi lapangan yang bervariasi. Selain itu, penyakit yang memiliki gejala serupa dan kualitas gambar yang terpengaruh oleh pencahayaan atau sudut pandang seringkali memperumit proses deteksi. Untuk mengatasi masalah ini, penelitian ini mengembangkan metode Adaptive Minimal Ensemble (AME), sebuah pendekatan machine learning berbasis arsitektur EfficientNet. AME secara adaptif menggabungkan kekuatan dua model terbaik untuk meningkatkan akurasi deteksi, sekaligus mengurangi kebutuhan sumber daya komputasi dibandingkan metode ensemble tradisional. Proses penelitian melibatkan pelatihan model pada dua jenis dataset: dataset Original (4062 gambar) dan dataset Augmented (4639 gambar). Data ini dibagi untuk pelatihan (60%), validasi (20%), dan pengujian (20%) menggunakan skema end-to-end dan fine-tuning. Hasil penelitian menunjukkan bahwa AME menghasilkan performa superior dibandingkan model EfficientNet B7 dan EfficientNet B0 secara individual. Pada dataset Augmented, AME mencapai akurasi pengujian tertinggi sebesar 99,35% dengan test loss terendah sebesar 0,0238. Sementara pada dataset Original, AME mencatatkan akurasi sebesar 98,32%. Performa ini dicapai dengan hanya menggunakan sekitar 10 juta parameter, jauh lebih efisien dibandingkan EfficientNet B7 yang memiliki 66 juta parameter.

## PENDAHULUAN

Salah satu masalah utama dalam industri pertanian adalah meningkatkan produktivitas dan kualitas hasil pertanian. Gangguan penyakit pada tanaman adalah salah satu hambatan terbesar yang dihadapi, yang dapat mengurangi hasil panen dan kualitas produk. Kondisi pertanian semakin memburuk di berbagai tempat, termasuk Indonesia, karena penyakit yang disebabkan oleh faktor biotik, seperti bakteri, jamur, dan virus, serta faktor abiotik, seperti kelembaban dan suhu yang tidak

sesuai. Oleh karena itu, diperlukan metode kreatif untuk mengidentifikasi dan mengendalikan penyakit. Anggur merupakan salah satu jenis buah yang dapat tumbuh di Indonesia yang berasal dari wilayah subtropis. Serangan hama adalah salah satu penyakit yang dapat menyerang buah anggur. Serangan hama dapat menyebabkan pertumbuhan tanaman terganggu hingga 40 hingga 70 persen, kulit buah menjadi kisut, rasa buah menjadi tidak manis, jumlah buah yang dihasilkan berkurang, dan fase generatif [1]. Maka dari itu diperlukan sebuah metode dalam mendeteksi penyakit daun pada tanaman anggur untuk mencegah dan mengurangi penyebarannya.

Pertanian memainkan peran penting dalam perekonomian global, dengan tanaman anggur (*Vitis vinifera*) menjadi salah satu komoditas utama di banyak negara penghasil anggur, seperti Prancis, Italia, dan Amerika Serikat. Tanaman anggur memiliki nilai ekonomi yang tinggi sebagai bahan baku industri pangan, minuman, dan produk olahan lainnya. Namun, tanaman anggur rentan terhadap berbagai penyakit yang dapat merusak kualitas dan kuantitas hasil panen. Penyakit-penyakit seperti *downy mildew*, *powdery mildew*, *black rot*, dan *botrytis bunch rot* sering menyerang tanaman anggur dan dapat menyebabkan kerusakan yang signifikan pada daun, batang, dan buah [2].

Deteksi penyakit tanaman secara dini sangat penting untuk mengurangi kerusakan yang lebih luas dan meningkatkan hasil panen. Metode tradisional yang melibatkan pemeriksaan visual oleh petani atau ahli pertanian memiliki keterbatasan, antara lain ketergantungan pada keahlian manusia dan waktu yang dibutuhkan untuk memeriksa tanaman dalam jumlah besar. Dengan meningkatnya skala pertanian dan kompleksitas penyakit yang menyerang tanaman, metode manual ini menjadi kurang efisien. Oleh karena itu, diperlukan pendekatan otomatis berbasis teknologi yang lebih cepat dan akurat, seperti pengolahan citra digital dan teknik pembelajaran mesin (*machine learning*) [3].

Penggunaan *computer vision* dan teknik pembelajaran mesin dalam klasifikasi penyakit tanaman telah menunjukkan hasil yang menjanjikan. Berbagai penelitian telah mengembangkan sistem untuk mendeteksi penyakit pada tanaman anggur melalui analisis citra daun dan buah yang terinfeksi [4]. Meskipun demikian, beberapa studi, seperti yang dilakukan oleh Wibowo et al. (2020), menemukan bahwa kualitas citra yang dipengaruhi oleh faktor lingkungan seperti pencahayaan dan sudut pandang dapat mengurangi akurasi deteksi, sehingga masih diperlukan metode yang dapat mengatasi masalah tersebut [5]. Meskipun demikian, salah satu tantangan utama dalam klasifikasi penyakit tanaman adalah adanya tumpang tindih antara gejala penyakit yang satu dengan yang lainnya, serta kualitas citra yang dipengaruhi oleh faktor pencahayaan, sudut pandang, dan gangguan noise. Hal ini membuat sistem klasifikasi tradisional sering kali tidak dapat diandalkan dalam kondisi lapangan yang variatif.

Untuk mengatasi tantangan ini, pendekatan ensemble learning telah muncul sebagai solusi yang dapat meningkatkan akurasi sistem klasifikasi dengan menggabungkan hasil dari beberapa model prediksi [6]. Pendekatan ini juga telah dibahas oleh Pratama et al. (2021), yang mengimplementasikan teknik ensemble untuk meningkatkan ketahanan sistem terhadap data yang bervariasi, terutama dalam klasifikasi penyakit tanaman [7]. Namun, penggunaan metode ensemble seringkali memerlukan sumber daya komputasi yang besar dan memakan waktu, terutama jika jumlah model yang digunakan sangat banyak. Oleh karena itu, pendekatan *Adaptive Minimal Ensemble* (AME) menjadi alternatif yang menarik. AME merupakan teknik ensemble yang memilih secara adaptif model-model klasifikasi yang paling relevan dan efisien untuk setiap tugas tertentu, yang mengarah pada pengurangan kompleksitas komputasi tanpa mengorbankan akurasi [8].

Penelitian ini bertujuan untuk mengembangkan dan mengimplementasikan metode *Adaptive Minimal Ensemble* dalam klasifikasi penyakit tanaman anggur. Dengan menggunakan AME, diharapkan sistem klasifikasi dapat memberikan akurasi yang lebih tinggi dalam mendeteksi penyakit pada tanaman anggur sekaligus mengurangi penggunaan sumber daya komputasi. Selain itu, penelitian ini juga diharapkan dapat memberikan solusi praktis bagi petani untuk mendeteksi penyakit pada tanaman anggur secara otomatis dan lebih efisien, yang pada gilirannya dapat meningkatkan produktivitas dan kualitas hasil pertanian.

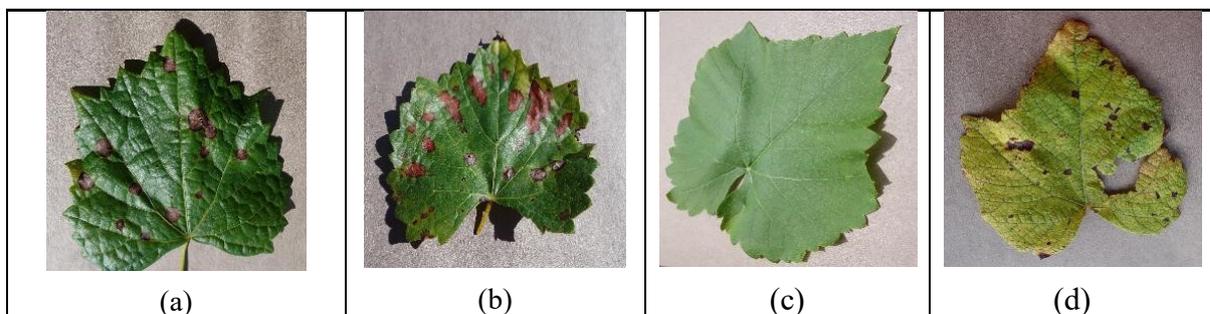
## TINJAUAN PUSTAKA

### Adaptive Minimal Ensemble

Adaptive Minimal Ensembling adalah pendekatan Machine Learning baru yang bertujuan untuk menggabungkan kekuatan beberapa model secara efektif untuk meningkatkan akurasi klasifikasi dan mengurangi kompleksitas komputasi [9]. Adaptive Minimal Ensembling mengintegrasikan fitur yang diekstraksi oleh model sebelum tahap klasifikasi, berbeda dengan teknik ensembling konvensional yang menggabungkan hasil akhir dari banyak model (Weak Classifier). Hal ini memberikan keseimbangan yang ideal antara kinerja dan efisiensi sumber daya komputasi, terutama untuk aplikasi berbasis data gambar seperti identifikasi penyakit tanaman. Adaptive Minimal Ensembling memiliki kemampuan untuk menghindari kelebihan data yang sering terjadi pada metode ensembling konvensional [10]. Metode ini mampu mempertahankan tingkat akurasi tinggi sekaligus meminimalkan konsumsi daya komputasi dengan hanya menggunakan dua model berbasis EfficientNet-b0 dan penggabungan pada tingkat fitur. Teknik-teknik ini memastikan bahwa model berfungsi dengan baik pada kedua data latih dan data yang belum pernah dilihat sebelumnya. Adaptive Minimal Ensembling terbukti sangat efektif dalam mendeteksi penyakit tanaman [11]. Studi sebelumnya menunjukkan bahwa penggabungan adaptif minimal berbasis CNN, terutama dengan varian EfficientNet, dapat mencapai akurasi testing hampir seratus persen pada dataset seperti PlantVillage.

### Dataset dalam Klasifikasi Penyakit Tanaman

Dataset sangat penting untuk pengembangan model pembelajaran mesin, khususnya untuk klasifikasi citra dalam bidang pertanian. Keberhasilan model dalam menemukan dan mengklasifikasikan penyakit tanaman secara akurat dipengaruhi oleh kualitas dataset [12]. PlantVillage adalah dataset yang paling banyak digunakan dalam penelitian ini, dengan berbagai gambar tanaman yang menunjukkan kondisi sehat dan yang terinfeksi oleh penyakit seperti bakteri, virus, dan jamur patogen. Dataset PlantVillage dikembangkan dengan lebih dari 54.000 gambar tanaman dari berbagai spesies, salah satunya tanaman anggur, dan memiliki keragaman jenis tanaman dan penyakit yang luar biasa.

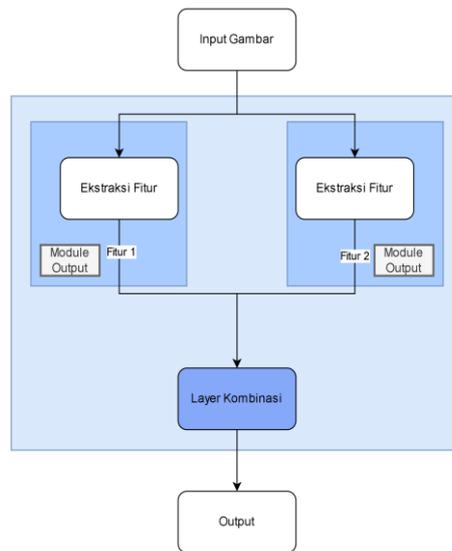


Gambar 1. Contoh gambar dataset penyakit daun anggur. a) Black Rot, b) Black Measles, c) Healthy, d) Leaf Blight.

Pada gambar 1 diperlihatkan untuk penyakit tanaman anggur dalam dataset *Original* terdapat 4062 gambar yang terbagi menjadi empat kelas, untuk gambar a yaitu *black rot*, untuk gambar b yaitu *black measles*, untuk gambar c yaitu *healthy* dan gambar d yaitu *leaf blight*. Sedangkan pada dataset *Augmented* terdapat 4639 gambar yang terbagi menjadi empat kelas tersebut. Data penyakit Anggur baik *Original* maupun *Augmented* kemudian akan dibagi dengan skala 6 : 2 : 2, yang dimana 60 persen data Training, 20 persen data Validasi, dan yang terakhir 20 persen data Testing.

## METODE

### Pemilihan Model

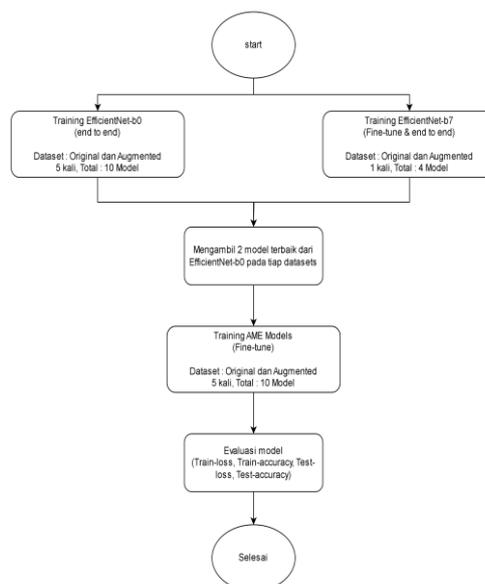


Gambar 2. Flowchart Model

Pada Gambar 2 dijelaskan struktur utama model penelitian Berbasis Adaptive Minimal Ensembling. Dua arsitektur utama *EfficientNet*, *EfficientNet-b7* dan *EfficientNet-b0*, digunakan untuk membangun model klasifikasi penyakit tanaman dalam penelitian. *EfficientNet-b7* dipilih karena memiliki jumlah parameter yang paling banyak dibandingkan varian lainnya, yaitu sekitar 66 juta, yang memungkinkan model untuk menangkap lebih banyak pola dan fitur kompleks dari data citra, yang diharapkan dapat meningkatkan akurasi klasifikasi. Sedangkan, *EfficientNet-b0* dipilih karena memiliki jumlah parameter yang lebih sedikit, yaitu sekitar 5 juta, tetapi tetap unggul dalam akurasi. Hal ini memungkinkan untuk digunakan dengan baik tanpa mengurangi performa secara signifikan.

### Alur Penelitian

Penelitian ini dilakukan melalui beberapa tahap.



Gambar 3. Flowchart Alur Penelitian

Pada Gambar 2 menjelaskan penelitian dilakukan melalui beberapa langkah. Pertama, model *EfficientNet-b7* dilatih menggunakan dua jenis dataset—dataset Original dan dataset Augmented. Dataset diperoleh dari Dataset *PlantVillage* untuk gambar tanaman anggur yang terbagi menjadi 4 kelas *black rot*, *black measles*, *healthy*, dan *leaf blight*. Pada dataset *Original* terdapat gambar asli penyakit daun anggur dalam berbagai kondisi berjumlah 4062 gambar. Pada dataset *Augmented* data dimodifikasi dari dataset original atau asli yang kemudian diubah menggunakan teknik augmentasi data untuk meningkatkan variasi dari data, terdapat 4639 gambar pada data *Augmented* yang tersusun atas 4 kelas yang sama seperti data *Original*.

Untuk setiap dataset, model dilatih menggunakan dua teknik, yaitu fine-tuning dan end-to-end. Dengan demikian, empat model *EfficientNet-b7* dihasilkan. Selanjutnya, model *EfficientNet-b0* dilatih dari ujung ke ujung pada kedua dataset, dengan setiap pelatihan dilakukan lima kali untuk masing-masing dataset. Dari sepuluh model *EfficientNet-b0* yang dihasilkan, dua model yang paling akurat dari masing-masing dataset dipilih untuk digunakan sebagai dasar dalam membangun model *AME*. Pelatihan model *AME* adalah langkah selanjutnya. Model ini dibangun berdasarkan dua model *EfficientNet-b0* unggulan yang telah dipilih sebelumnya. Untuk setiap dataset, baik *Original* maupun *Augmented*, pelatihan dilakukan secara fine-tuning lima kali. Hasil terbaik diambil dari setiap pelatihan, sehingga dihasilkan sepuluh model *AME*. Setelah hasil model didapatkan, model kemudian digunakan untuk membandingkan performa dari *EfficientNet-b7*, *EfficientNet-b0*, dan *AME* serta digunakan juga dalam mengevaluasi keunggulan pendekatan Adaptive Minimal Ensembling dalam meningkatkan akurasi klasifikasi penyakit tanaman.

## HASIL DAN PEMBAHASAN

### Model Ensemble

Model *Adaptive Minimal Ensemble* yang terdiri dari dua model *EfficientNet B0*, memiliki jumlah parameter sekitar 8 juta. Ini membuktikan bahwa arsitektur *AME* efisien dalam total parameternya dibandingkan jika menggunakan *ensemble* secara voting yang dapat membuat total parameter dua kali dari total *base model* nya. Dan Jika dibandingkan dengan *EfficientNet B7* yang memiliki total parameter sekitar 66 juta, model *AME* yang memiliki parameter lebih sedikit akan memerlukan daya komputasi yang lebih efisien dibandingkan *EfficientNet B7*.

Tabel 1. Perbandingan Jumlah Parameter Model

| Model                            | Total Parameter |
|----------------------------------|-----------------|
| <i>EfficientNet B7</i>           | 66.347.960      |
| <i>EfficientNet B0</i>           | 5.288.548       |
| <i>Adaptive Minimal Ensemble</i> | 8.025.340       |

### Dataset Augmented

Pada hasil pelatihan, model *EfficientNet B7* dengan skema *End to End* menghasilkan akurasi pengujian terendah, yaitu 0,8055, dengan *Train Loss* Akhir sebesar 0,1789 dan *Test Loss* Akhir sebesar 2,0378. Namun, ketika dilatih menggunakan skema *Fine Tune*, performa model ini meningkat secara signifikan dengan *Test Accuracy* mencapai 0,9828 dan *Test Loss* Akhir yang jauh lebih rendah, yaitu 0,0547. Sementara itu, model *EfficientNet B0 (WEAK MODEL 1)* pada skema *End to End* menunjukkan hasil yang lebih baik dibandingkan *EfficientNet B7 End to End*, dengan *Test Accuracy* sebesar 0,9763 dan *Test Loss* Akhir sebesar 0,0889. Model lain, yaitu *EfficientNet B0 (WEAK MODEL 2)*, juga menunjukkan performa yang serupa dengan sedikit peningkatan pada akurasi pengujian hingga 0,9675. Di sisi lain, *AME EfficientNet B0*, yang dilatih menggunakan skema *Fine Tune*, mencatat performa terbaik dengan *Test Accuracy* mencapai 0,9935 dan *Test Loss* Akhir terendah, yaitu 0,0238. Hal ini menunjukkan bahwa skema *Fine Tune* secara konsisten memberikan performa yang lebih baik dibandingkan skema *End to End*.

Tabel 2. Performa Model dalam Dataset *Augmented*

| Model                                 | Skema             | Train Loss Akhir | Train Accuracy Akhir | Test Loss Akhir | Test Accuracy Akhir |
|---------------------------------------|-------------------|------------------|----------------------|-----------------|---------------------|
| <i>EfficientNet B7</i>                | <i>End to End</i> | 0,1789           | 0,9463               | 2,0378          | 0,8055              |
| <i>EfficientNet B7</i>                | <i>Fine Tune</i>  | 308,1956         | 0,9473               | 0,0547          | 0,9828              |
| <i>EfficientNet B0 (WEAK MODEL 1)</i> | <i>End to End</i> | 0,0876           | 0,9713               | 0,0889          | 0,9763              |
| <i>EfficientNet B0 (WEAK MODEL 2)</i> | <i>End to End</i> | 0,0751           | 0,9739               | 0,0846          | 0,9675              |
| <i>AME EfficientNet B0</i>            | <i>Fine Tune</i>  | 0,032            | 0,988                | 0,0238          | 0,9935              |

### Dataset *Original*

Pada dataset *Original*, model *EfficientNet B7* yang dilatih dengan skema *End to End* menghasilkan akurasi pengujian sebesar 0,9832 dengan *Train Loss Akhir* sebesar 0,1956 dan *Test Loss Akhir* sebesar 0,0649. Dengan menggunakan skema *Fine Tune*, model ini menunjukkan peningkatan performa, mencapai *Test Accuracy* sebesar 0,988 dan *Test Loss Akhir* yang lebih rendah, yaitu 0,0496. Model *EfficientNet B0 (WEAK MODEL 1)* yang dilatih secara *End to End* menunjukkan performa akurasi pengujian sebesar 0,9856 dengan *Train Loss Akhir* sebesar 0,0831 dan *Test Loss Akhir* sebesar 0,0495, yang lebih unggul dibandingkan *WEAK MODEL 2* pada akurasi pengujian. Model *EfficientNet B0 (WEAK MODEL 2)* dengan skema *End to End* mencatat *Test Accuracy* sebesar 0,9784 dengan *Test Loss Akhir* sedikit lebih tinggi, yaitu 0,0651. Terakhir, model *AME EfficientNet B0* yang dilatih dengan skema *Fine Tune* memberikan hasil yang sangat baik, dengan *Test Accuracy* sebesar 0,9832 dan *Test Loss Akhir* sebesar 0,0642.

Tabel 3. Performa Model dalam Dataset *Original*

| Model                                 | Skema             | Train Loss Akhir | Train Accuracy Akhir | Test Loss Akhir | Test Accuracy Akhir |
|---------------------------------------|-------------------|------------------|----------------------|-----------------|---------------------|
| <i>EfficientNet B7</i>                | <i>End to End</i> | 0,1956           | 0,9368               | 0,0649          | 0,9832              |
| <i>EfficientNet B7</i>                | <i>Fine Tune</i>  | 307,8861         | 0,9674               | 0,0496          | 0,988               |
| <i>EfficientNet B0 (WEAK MODEL 1)</i> | <i>End to End</i> | 0,0831           | 0,9729               | 0,0495          | 0,9856              |
| <i>EfficientNet B0 (WEAK MODEL 2)</i> | <i>End to End</i> | 0,0935           | 0,9691               | 0,0651          | 0,9784              |
| <i>AME EfficientNet B0</i>            | <i>Fine Tune</i>  | 0,0019           | 0,9945               | 0,0642          | 0,9832              |

Hasil pengujian pada dataset *Augmented* menunjukkan bahwa model *Adaptive Minimal Ensemble* berbasis *EfficientNet B0* memiliki akurasi yang lebih tinggi daripada model *EfficientNet B7* yang dilatih secara *End to End* maupun *Fine Tune*. Dalam dataset *Original*, model *AME* memiliki performa yang sama dengan *EfficientNet B7* yang dilatih secara *End to End*. Namun, masih lebih rendah 0.0048 dibandingkan *EfficientNet B7* yang dilatih secara *Fine Tune*. Hal ini masih membuat model *AME* menjadi lebih superior karena perbedaan akurasi yang sangat kecil jika dibandingkan dengan total parameter yang ada model *AME* dan *EfficientNet B7*.

## KESIMPULAN

Model Adaptive Minimal Ensemble (AME) menunjukkan performa yang sangat unggul dalam proses klasifikasi penyakit tanaman anggur, baik pada dataset Augmented maupun Original. Pada dataset Augmented, AME berhasil mencapai akurasi pengujian tertinggi sebesar 0.9935, sementara pada dataset Original, model ini mencatatkan akurasi pengujian yang juga sangat baik, yaitu 0.9832. Pencapaian ini mengindikasikan bahwa AME dengan total parameter sekitar 8 juta, Tidak hanya mampu bersaing dengan model-model lain yang memiliki jumlah parameter lebih banyak. Seperti EfficientNet B7 yang memiliki total parameter 66 Juta, Tetapi juga mampu mengungguli performa mereka secara konsisten. Hal ini membuktikan efisiensi dan efektivitas pendekatan ensemble minimal yang digunakan oleh AME.

## UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak yang telah mendukung dan berkontribusi dalam penyelesaian penelitian ini. Semoga penelitian ini dapat memberikan kontribusi positif dalam pengembangan teknologi pertanian, khususnya dalam deteksi penyakit tanaman anggur, dan bermanfaat bagi dunia akademik maupun praktisi di bidang pertanian.

## DAFTAR PUSTAKA

- [1] M. A. Hasan, Y. Riyanto, and D. Riana, "Klasifikasi penyakit citra daun anggur menggunakan model CNN-VGG16," *Jurnal Teknologi dan Sistem Komputer*, vol. 9, no. 4, pp. 218-223, Oct. 2021.
- [2] Coombe, B. G., & McCarthy, M. G. (2000). *The Grapevine: From Ancient History to Modern Biotechnology*. *Journal of Experimental Botany*, 51(347), 635-650.
- [3] Picon, A., Kallel, S., & Hamrouni, S. (2019). *A Machine Learning Approach to Detect Plant Diseases Based on Visual Symptoms*. *Computers and Electronics in Agriculture*, 156, 302-309.
- [4] Wibowo, A., et al. (2020). "Pengaruh faktor lingkungan terhadap kualitas citra untuk deteksi penyakit tanaman." *Jurnal Pengolahan Citra dan Teknologi Pertanian*.
- [5] Chandrashekar, P., Saini, H., & Agarwal, A. (2018). *Detection of Plant Diseases Using Image Processing and Machine Learning: A Review*. *International Journal of Computer Applications*, 179(40), 6-12.
- [6] Zhou, Z. H. (2012). *Ensemble Methods: Foundations and Algorithms*. CRC Press.
- [7] Pratama, M., et al. (2021). "Implementasi ensemble learning untuk klasifikasi penyakit tanaman." *Jurnal Ilmu Komputer dan Pertanian*.
- [8] Yao, Y., Wang, L., & Han, S. (2015). *Adaptive Ensemble Learning for Classification*. *Knowledge-Based Systems*, 80, 206-213.
- [9] E. J. Marmel, *Word 2016*. Indianapolis, IN: Visual, an imprint of Wiley, John Wiley & Sons, Inc, 2016.
- [10] Pristyanto, Y. (2019). Penerapan Metode Ensemble Untuk Meningkatkan Kinerja Algoritme Klasifikasi Pada Imbalanced Dataset. *Jurnal Teknoinfo*, 13(1), 11. <https://doi.org/10.33365/jti.v13i1.184>.
- [11] M. Nur et al., "Evaluation of Novel Integrated Dielectric Barrier Discharge Plasma as Ozone Generator," *Bull. Chem. React. Eng. Catal.*, vol. 12, no. 1, p. 24, Apr. 2017.
- [12] R. Macfarlane, *Original Copy: Plagiarism and Originality in Nineteenth-Century Literature*, 1 edition. Oxford ; New York: Oxford University Press, 2007.