

Benchmark Multi-Model untuk Klasifikasi Daun *Amaranthus Viridis*

Muhammad Ainul Fikri^{*1}, Iqbal Kurniawan Asmar Putra², Apriska Prameswari³, Puji Hastuti⁴

^{*1,4}Politeknik Negeri Jember, Jl. Mastrip PO BOX 164, Jember, Jawa Timur

^{2,3}Politeknik Negeri Padang, Limau Manis, Kec. Pauh, Kota Padang, Sumatra Barat

Email: ^{*1}m.ainulfikri@polije.ac.id

Abstrak—Penelitian ini menyajikan *benchmark* multi-model untuk mengidentifikasi algoritma machine learning yang paling efektif dalam klasifikasi kesehatan daun *Amaranthus viridis* melalui evaluasi sepuluh model menggunakan pipeline yang konsisten dan terkontrol. Dataset terdiri atas 165 citra daun dari London South Bank University, yang terbagi ke dalam kelas sehat dan terinfeksi dengan distribusi tidak seimbang. Tahapan penelitian meliputi preprocessing citra, ekstraksi fitur berbasis piksel, pembagian data menggunakan *Stratified Train-Test Split*, serta evaluasi menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Hasil menunjukkan bahwa *XGBoost* mencapai performa terbaik dengan *F1-Score* sebesar 96.78%, diikuti oleh *AdaBoost* dan *Bagging*, sementara model sederhana menunjukkan performa lebih rendah. Analisis menunjukkan adanya bias terhadap kelas mayoritas akibat ketidakseimbangan data, sehingga *F1-Score* menjadi metrik yang lebih representatif dibandingkan *Accuracy*. Penelitian ini menegaskan bahwa model berbasis *boosting* lebih efektif dalam menangani data tidak seimbang serta menyediakan *benchmark* yang dapat dijadikan acuan dalam pengembangan sistem pertanian cerdas berbasis *Internet of Things* (IoT), di mana citra daun yang diperoleh dari kamera lapangan dapat dianalisis secara otomatis untuk mendukung deteksi dini gangguan kesehatan tanaman dan pengambilan keputusan secara *real-time*.

Kata Kunci—*Amaranthus Viridis*, Klasifikasi Daun, Machine Learning, Data Tidak Seimbang, Ensemble Boosting

I. PENDAHULUAN

AMARANTHUS *viridis* L. (bayam hijau) merupakan tanaman herba dari famili Amaranthaceae yang berpotensi mendukung ketahanan pangan dan peningkatan kualitas gizi masyarakat karena adaptif terhadap lingkungan tropis, memiliki efisiensi penggunaan air yang tinggi melalui jalur fotosintesis C4, serta dapat dibudidayakan pada berbagai sistem pertanian modern [1], [2], [3], [4]. Selain kaya akan protein, vitamin, dan mineral penting, tanaman ini juga memiliki aktivitas farmakologis seperti antioksidan, anti-inflamasi, dan antidiabetik yang menjadikannya bernilai sebagai pangan fungsional [5], serta berkontribusi dalam upaya penanganan masalah kesehatan seperti anemia dan stunting [6], [7], [8]. Di Indonesia, peningkatan nilai ekonomi dan pemanfaatan sistem budidaya modern, termasuk hidroponik, mendorong kebutuhan akan pemantauan kualitas tanaman yang lebih

efektif [9], [10], [11]. Salah satu indikator utama kualitas tanaman adalah kondisi daun, karena perubahan warna, bentuk, maupun kerusakan pada daun dapat mencerminkan adanya gangguan kesehatan tanaman akibat defisiensi nutrisi, serangan hama, atau kondisi lingkungan yang tidak optimal [12], [13], [14], [15], [16], [17].

Proses identifikasi kondisi daun secara manual memiliki berbagai keterbatasan, di antaranya subjektivitas pengamatan, inkonsistensi hasil, serta inefisiensi dalam skala besar [18], [19], [20]. Seiring dengan meningkatnya kebutuhan akan sistem pertanian yang presisi, pendekatan berbasis kecerdasan buatan, khususnya machine learning, mulai banyak digunakan untuk mengotomatisasi proses klasifikasi dan analisis data [21], [22]. Berbagai algoritma *machine learning* seperti *Logistic Regression*, *Decision Tree*, *Random Forest*, *Support Vector Machine*, *K-Nearest Neighbors*, *Naive Bayes*, hingga metode *ensemble* seperti *AdaBoost*, *Bagging*, *Gradient Boosting*, dan *XGBoost* telah menunjukkan kemampuan yang baik dalam menangani permasalahan klasifikasi pada berbagai domain [23], [24].

Meskipun demikian, sebagian besar penelitian yang ada masih berfokus pada penerapan model tertentu atau terbatas pada domain tanaman lain, tanpa melakukan evaluasi komprehensif terhadap berbagai algoritma dalam satu kerangka eksperimen yang terstandarisasi [25], [26], [27]. Secara khusus, pada konteks *Amaranthus viridis*, belum ditemukan penelitian yang secara sistematis melakukan *benchmark multi-model machine learning* untuk mengklasifikasikan kondisi kesehatan daun [28], [29]. Ketiadaan *benchmark* ini menyebabkan belum adanya acuan yang jelas mengenai model mana yang paling optimal dalam menangani karakteristik data pada tanaman *A. viridis*, baik dari sisi akurasi maupun efisiensi [27], [30], [31].

Selain itu, banyak penelitian sebelumnya belum menerapkan pendekatan evaluasi yang terkontrol (*controlled evaluation*) dengan pipeline yang konsisten di seluruh model, sehingga perbandingan performa menjadi kurang objektif dan sulit direplikasi [32]. Variasi dalam tahap *preprocessing*, pembagian data, serta teknik evaluasi sering kali menjadi faktor bias yang memengaruhi hasil akhir. Oleh karena itu, diperlukan suatu pendekatan yang tidak hanya membandingkan berbagai model, tetapi juga memastikan bahwa seluruh proses dilakukan dalam kerangka kerja yang terstandarisasi (*standardized pipeline*) untuk menghasilkan evaluasi yang adil dan dapat diper-

tanggungjawabkan [33], [34].

Di sisi lain, perkembangan teknologi seperti *Internet of Things* (IoT) dan sistem hidroponik cerdas membuka peluang untuk mengintegrasikan proses akuisisi data dan analisis secara *real-time* [35]. Dalam sistem ini, data citra daun maupun parameter lingkungan dapat dikumpulkan secara kontinu dan dianalisis menggunakan model machine learning untuk mendukung pengambilan keputusan secara otomatis [36], [37]. Dalam implementasinya, model klasifikasi yang terintegrasi pada perangkat IoT dapat digunakan untuk mengidentifikasi kondisi daun secara otomatis segera setelah citra diperoleh, sehingga hasil perbandingan berbagai algoritma dalam penelitian ini menjadi penting sebagai dasar pemilihan model yang paling akurat dan efisien untuk diterapkan pada sistem monitoring tanaman cerdas. Oleh karena itu, pemilihan model yang tepat menjadi krusial agar sistem yang dikembangkan tidak hanya akurat, tetapi juga efisien dan dapat diimplementasikan pada perangkat dengan sumber daya terbatas [38], [39], [40].


Berdasarkan permasalahan tersebut, penelitian ini mengusulkan suatu pendekatan yang bersifat *first comparative study* dalam konteks klasifikasi kesehatan daun *Amaranthus viridis*, dengan melakukan evaluasi terhadap sepuluh algoritma *machine learning* dalam satu kerangka eksperimen yang terstandarisasi dan terkontrol. Penelitian ini bertujuan untuk mengklasifikasikan kondisi daun *A. viridis* ke dalam kategori sehat dan tidak sehat, serta menganalisis dan membandingkan performa masing-masing model secara komprehensif. Dengan pendekatan *standardized pipeline* dan *controlled evaluation*, hasil yang diperoleh diharapkan dapat memberikan *benchmark* yang jelas dan dapat dijadikan acuan dalam pengembangan sistem pertanian cerdas yang lebih akurat, efisien, dan aplikatif.

II. DESKRIPSI SISTEM

Sistem yang dikembangkan pada penelitian ini merupakan sistem klasifikasi citra berbasis machine learning untuk mengidentifikasi kondisi daun *Amaranthus viridis* ke dalam dua kelas, yaitu sehat (*healthy*) dan terinfeksi (*infected*). Alur sistem ditunjukkan pada Gambar 1, yang terdiri atas tahapan input dataset, preprocessing, pembagian data, pemodelan, dan evaluasi.

Dataset yang digunakan berasal dari London South Bank University dan terdiri atas 165 citra daun, yang meliputi 145 citra daun sehat dan 20 citra daun terinfeksi [41]. Distribusi kelas dipertahankan dalam kondisi aslinya tanpa proses *class balancing* untuk merepresentasikan kondisi nyata di lapangan serta menguji kemampuan model dalam menangani data yang tidak seimbang. Seluruh citra dikonversi ke format RGB, diubah ukurannya menjadi 128×128 piksel, dinormalisasi ke rentang $[0,1]$, kemudian direpresentasikan sebagai vektor fitur satu dimensi melalui proses *flattening*. Label kelas selanjutnya dikodekan secara numerik menggunakan *Label Encoder*.

Setelah *preprocessing*, dataset dibagi menggunakan metode *Stratified Train-Test Split* dengan rasio 80:20 untuk menjaga proporsi distribusi kelas pada data latih dan



Gambar 1. Alur Sistem

data uji. Berdasarkan pembagian tersebut, diperoleh 132 data untuk pelatihan dan 33 data untuk pengujian. Nilai *random_state* ditetapkan sebesar 42 untuk menjamin replikabilitas eksperimen.


Pada tahap pemodelan, sepuluh algoritma machine learning diimplementasikan menggunakan pipeline evaluasi yang sama, yaitu *Logistic Regression*, *Support Vector Machine* (SVM), *K-Nearest Neighbors* (KNN), *Decision Tree*, *Random Forest*, *Gradient Boosting*, *AdaBoost*, *Bagging*, *Extra Trees*, dan *XGBoost*. Untuk model yang sensitif terhadap skala fitur, yaitu *Logistic Regression*, SVM, dan KNN, diterapkan normalisasi menggunakan *StandardScaler* dengan skema fit pada data latih dan *transform* pada data uji guna mencegah *data leakage*. Sementara itu, model berbasis pohon tidak memerlukan normalisasi karena relatif tidak dipengaruhi oleh skala fitur.

Evaluasi performa dilakukan menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*, serta analisis *confusion matrix*. Pendekatan ini memungkinkan perbandingan performa antar model dilakukan secara objektif dalam kondisi eksperimen yang terkontrol sehingga dapat mengidentifikasi algoritma yang paling efektif untuk klasifikasi kesehatan daun *Amaranthus viridis*.

III. METODE

Penelitian ini dilaksanakan melalui enam tahapan utama sebagaimana ditunjukkan pada Gambar 2, yaitu studi literatur, penentuan *research gap*, pengumpulan dataset, pengujian, analisis, dan penarikan kesimpulan. Tahap studi literatur dilakukan untuk mengidentifikasi perkembangan penelitian terkait klasifikasi kesehatan tanaman berbasis citra serta penerapan *machine learning* dalam bidang pertanian. Berdasarkan kajian tersebut, dilakukan identifikasi *research gap* yang menunjukkan masih terbatasnya studi komparatif yang mengevaluasi berbagai algoritma *machine learning* pada klasifikasi kesehatan daun *Amaranthus viridis* menggunakan lingkungan eksperimen yang seragam. Temuan ini menjadi dasar dalam penyusunan desain penelitian dan pemilihan pendekatan *benchmark* multi-model.

Tahap berikutnya adalah pengumpulan dataset citra daun *Amaranthus viridis* yang terdiri atas kelas sehat dan terinfeksi. Dataset yang telah diperoleh kemudian




Gambar 2. Flowchart Penelitian

digunakan pada tahap pengujian melalui sistem klasifikasi yang dikembangkan. Pada tahap ini, sepuluh algoritma machine learning dievaluasi menggunakan prosedur eksperimen yang sama sehingga perbandingan performa dapat dilakukan secara objektif. Hasil pengujian selanjutnya dianalisis menggunakan berbagai metrik evaluasi untuk mengidentifikasi kelebihan dan keterbatasan masing-masing algoritma serta menentukan model yang memberikan performa terbaik.

Tahap akhir penelitian adalah penarikan kesimpulan berdasarkan hasil analisis yang telah dilakukan. Kesimpulan disusun untuk menjawab tujuan penelitian, yaitu mengidentifikasi algoritma machine learning yang paling efektif dalam klasifikasi kesehatan daun *Amaranthus viridis*, sekaligus memberikan rekomendasi dan arah pengembangan penelitian pada masa mendatang.

IV. HASIL DAN PEMBAHASAN

Gambar 3 menunjukkan *confusion matrix* dari seluruh model yang diuji. Secara umum, sebagian besar model mampu mengklasifikasikan kelas healthy dengan tingkat keberhasilan yang tinggi, yang ditunjukkan oleh dominasi nilai *True Negative* pada hampir seluruh *confusion matrix*. Namun, kesalahan klasifikasi masih ditemukan pada kelas *infected*, terutama dalam bentuk False Negative, yaitu kondisi ketika daun yang terinfeksi diprediksi sebagai daun sehat. Kesalahan ini menjadi perhatian utama karena dapat menyebabkan tanaman yang mengalami gangguan kesehatan tidak terdeteksi dan berpotensi menimbulkan dampak yang lebih besar pada proses budidaya. Pola tersebut mengindikasikan adanya pengaruh distribusi data yang tidak seimbang, di mana jumlah citra daun sehat jauh lebih banyak dibandingkan daun terinfeksi sehingga model cenderung mempelajari karakteristik kelas mayoritas dengan lebih baik.



Gambar 3. Confussion Matrix Keseluruhan Model

Ketidakseimbangan data menyebabkan nilai *Accuracy* yang tinggi belum tentu mencerminkan kemampuan model dalam mengenali kelas minoritas. Oleh karena itu, evaluasi tidak hanya dilakukan berdasarkan *Accuracy*, tetapi juga menggunakan *Precision*, *Recall*, dan terutama *F1-Score* yang mampu menggambarkan keseimbangan antara kemampuan model dalam mendeteksi kelas positif dan meminimalkan kesalahan klasifikasi. Berdasarkan hasil *confusion matrix*, model yang mampu mempertahankan jumlah *False Negative* yang rendah cenderung menghasilkan nilai *F1-Score* yang lebih baik.

Guna memperoleh gambaran kuantitatif yang lebih komprehensif, hasil evaluasi masing-masing model dirangkum pada Tabel I. Berdasarkan tabel tersebut, model berbasis ensemble boosting menunjukkan performa paling unggul dibandingkan model lainnya. XGBoost mencapai hasil terbaik dengan *Accuracy* sebesar 96,97%, *Precision* 97,07%, *Recall* 96,97%, dan *F1-Score* 96,78%. AdaBoost dan Bagging berada pada posisi berikutnya dengan *F1-Score* sebesar 93,03%, sedangkan SVM, KNN, Random Forest, dan Gradient Boosting menghasilkan performa yang relatif serupa dengan *F1-Score* sebesar 88,41%. Di sisi lain, Decision Tree, Logistic Regression, dan Naive Bayes menunjukkan performa yang lebih rendah, terutama dalam menjaga keseimbangan antara *Precision* dan *Recall*.

TABLE I
PERBANDINGAN PERFORMA MODEL

Model	Accuracy	Precision	Recall	F1-Score
XGBoost	96,97%	97,07%	96,97%	96,78%
AdaBoost	93,94%	94,33%	93,94%	93,03%
Bagging	93,94%	94,33%	93,94%	93,03%
Support Vector Machine	90,91%	91,76%	90,91%	88,41%
K-Nearest Neighbors	90,91%	91,76%	90,91%	88,41%
Random Forest	90,91%	91,76%	90,91%	88,41%
Gradient Boosting	90,91%	91,76%	90,91%	88,41%
Decision Tree	87,88%	85,43%	87,88%	86,06%
Logistic Regression	81,82%	85,41%	81,82%	83,31%
Naive Bayes	87,88%	77,23%	87,88%	82,21%

Perbedaan performa ini menunjukkan bahwa karakteristik data citra daun *Amaranthus viridis* lebih sesuai ditangani oleh metode *ensemble*, khususnya pendekatan *boosting* yang secara iteratif memberikan perhatian lebih besar pada sampel yang sebelumnya salah diklasifikasikan. Logistic Regression dan Naive Bayes memiliki keterbatasan dalam menangkap pola kompleks pada representasi fitur berbasis piksel, sedangkan Decision Tree cenderung menghasilkan model yang kurang stabil. Meskipun Random Forest mampu meningkatkan stabilitas melalui mekanisme bagging, peningkatan tersebut belum cukup untuk mengatasi dampak ketidakseimbangan data secara optimal. Sebaliknya, XGBoost berhasil mempertahankan keseimbangan performa antar kelas dengan jumlah kesala-

han klasifikasi yang paling rendah, sebagaimana terlihat pada *confusion matrix* maupun nilai *F1-Score* tertinggi yang diperoleh. Temuan ini menunjukkan bahwa pada kasus klasifikasi kesehatan daun dengan distribusi data yang tidak seimbang, *F1-Score* merupakan indikator yang lebih representatif dibandingkan *Accuracy*, dan *XGBoost* menjadi model yang paling efektif untuk digunakan pada dataset yang diuji.

V. KESIMPULAN

Penelitian ini bertujuan untuk mengklasifikasikan kondisi daun *Amaranthus viridis* menjadi sehat dan terinfeksi menggunakan sepuluh algoritma machine learning dalam kerangka eksperimen yang terstandarisasi dan terkontrol. Dataset yang digunakan berupa citra daun dengan distribusi tidak seimbang (*imbalanced*), sehingga mencerminkan kondisi nyata di lapangan. Proses dilakukan melalui tahapan preprocessing yang meliputi konversi RGB, *resize*, normalisasi, dan *flattening*, kemudian dibagi menggunakan *Stratified Train-Test Split*. Evaluasi dilakukan menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score* untuk memperoleh gambaran performa model secara komprehensif.

Hasil penelitian menunjukkan bahwa model *ensemble boosting*, terutama *XGBoost*, memberikan performa terbaik dengan *Accuracy* sebesar 96,97%, *Precision* 97,07%, *Recall* 96,97%, dan *F1-Score* 96,78%. Berdasarkan *confusion matrix*, model *XGBoost* berhasil mengklasifikasikan seluruh 29 citra daun sehat dengan benar (TN = 29, FP = 0) serta mendeteksi 3 dari 4 citra daun terinfeksi (TP = 3, FN = 1). Hasil ini menunjukkan kemampuan model yang baik dalam mempertahankan keseimbangan performa pada kedua kelas meskipun dataset memiliki distribusi yang tidak seimbang. Ketidakseimbangan data menyebabkan sebagian model cenderung bias terhadap kelas mayoritas, sehingga *F1-Score* menjadi metrik yang lebih representatif dibandingkan *Accuracy*. Secara keseluruhan, model berbasis *boosting* terbukti lebih robust dibandingkan algoritma lainnya. Untuk penelitian selanjutnya, disarankan melakukan penambahan data pada kelas minoritas, menerapkan teknik data *balancing* seperti SMOTE atau *undersampling*, serta mengeksplorasi pendekatan deep learning guna meningkatkan kemampuan deteksi pada kelas terinfeksi.

DAFTAR PUSTAKA

- [1] P. S. Tong, K. Ning Chew, H. Yin Yik, and J. Zhe Tan, "Response of *Amaranthus viridis* Plant Functional Traits to NPK 12:12:17 and NPK 15:15:15 Fertilizers," *Biotropia*, vol. 31, no. 1, pp. 34–43, Apr. 2024, doi: <https://doi.org/10.11598/btb.2024.31.1.2020>.
- [2] The University of Queensland, *Biology of Amaranthus retroflexus and Amaranthus viridis*, 2021, doi: <https://doi.org/10.14264/2cb1159>.
- [3] M. Meeran, A. Sami, M. Haider, and M. Umar, "Multivariate Analysis for Morphological Traits of *Amaranthus viridis*," *Bulletin of Biological and Allied Sciences Research*, vol. 2023, no. 1, p. 46, Sep. 2023, doi: <https://doi.org/10.54112/bbasr.v2023i1.46>.
- [4] N. Tsutsumi, M. Tohya, T. Nakashima, and O. Ueno, "Variations in Structural, Biochemical, and Physiological Traits of Photosynthesis and Resource Use Efficiency in *Amaranthus* Species (NAD-ME-Type C4)," *Plant Production Science*, vol. 20, no. 3, pp. 300–312, Jul. 2017, doi: <https://doi.org/10.1080/1343943X.2017.1320948>.
- [5] J. Siamey, J. N. Amisah, P. A. Ofori, R. A. Amoah, E. O. Mensah, and D. A. Kotey, "Agro-morphological and Molecular Characterization of *Amaranthus* Genotypes," *PLoS ONE*, vol. 20, no. 9, p. e0328567, Sep. 2025, doi: <https://doi.org/10.1371/journal.pone.0328567>.
- [6] M. H. Netshimbupfe, J. Berner, and C. Gouws, "The Interactive Effects of Drought and Heat Stress on Photosynthetic Efficiency and Biochemical Defense Mechanisms of *Amaranthus* Species," *Plant-Environment Interactions*, vol. 3, no. 5, pp. 212–225, Oct. 2022, doi: <https://doi.org/10.1002/pei3.10092>.
- [7] O. R. Aderibigbe, O. O. Ezekiel, S. O. Owolade, J. K. Koresse, B. Sturm, and O. Hensel, "Exploring the Potentials of Underutilized Grain Amaranth (*Amaranthus* spp.) Along the Value Chain for Food and Nutrition Security: A Review," *Critical Reviews in Food Science and Nutrition*, vol. 62, no. 3, pp. 656–669, Jan. 2022, doi: <https://doi.org/10.1080/10408398.2020.1825323>.
- [8] O. N. Ruth, K. Unathi, N. Nomali, and M. Chinsamy, "Underutilization Versus Nutritional-Nutraceutical Potential of the *Amaranthus* Food Plant: A Mini-Review," *Applied Sciences*, vol. 11, no. 15, p. 6879, Jul. 2021, doi: <https://doi.org/10.3390/app11156879>.
- [9] T. P. L. da Cunha-Chiamolera *et al.*, "Crop Productivity, Phytochemicals, and Bioactivities of Wild and Grown in Controlled Environment Slender Amaranth (*Amaranthus viridis* L.)," *Agronomy*, vol. 14, no. 9, p. 2038, Sep. 2024, doi: <https://doi.org/10.3390/agronomy14092038>.
- [10] G. Ravichandran *et al.*, "A Comprehensive Review of Advanced Seed Treatment Techniques to Enhance *Amaranthus* Cultivation and Productivity," *Plant Science Today*, Apr. 2025, doi: <https://doi.org/10.14719/pst.8047>.
- [11] M. P. Deepthi, S. Nivethitha, K. Saminathan, R. T. Narendhirakannan, N. Karmegam, and P. Kathireswari, "Effect of Vermiwash Prepared from Livestock Biowaste as Vermiponics Medium on the Growth and Biochemical Indices of *Amaranthus viridis* L.," *Environmental Technology & Innovation*, vol. 21, p. 101300, Feb. 2021, doi: <https://doi.org/10.1016/j.eti.2020.101300>.
- [12] K. Venkatesh, K. J. Naik, and A. Shankar, "Quantum Convolution Neural Network for Multi-Nutrient Detection and Stress Identification in Plant Leaves," *Multimedia Tools and Applications*, vol. 83, no. 24, pp. 65663–65685, Jan. 2024, doi: <https://doi.org/10.1007/s11042-023-17992-1>.
- [13] S. Ramasubbareddy, M. Manik, T. A. S. Srinivas, and K. Govinda, "Plants Nutrient Deficiency Identification Using Classification," in *Advances in Intelligent Systems and Computing*, 2021, pp. 329–338, doi: https://doi.org/10.1007/978-981-15-5400-1_34.
- [14] F. Talebzadeh and C. Valeo, "Evaluating the Effects of Environmental Stress on Leaf Chlorophyll Content as an Index for Tree Health," *IOP Conference Series: Earth and Environmental Science*, vol. 1006, no. 1, p. 012007, Apr. 2022, doi: <https://doi.org/10.1088/1755-1315/1006/1/012007>.
- [15] J. He, K. Goh, L. Qin, Y. Shen, and H. Rahardjo, "Identifying Plant Healthy Indicators of Five Tropical Perennials Using Certain Leaf Physiological Traits During Drought Stress and Re-Watering," *Horticulturae*, vol. 11, no. 3, p. 230, Feb. 2025, doi: <https://doi.org/10.3390/horticulturae11030230>.
- [16] R. Bulgari *et al.*, "Characterisation of Combined Abiotic and Biotic Stresses Effects on Lettuce Plants via a Multi-analysis Approach," *Frontiers in Plant Science*, vol. 16, May 2025, doi: <https://doi.org/10.3389/fpls.2025.1550577>.
- [17] M. K. Oni and T. T. Prama, "A Comprehensive Dataset of Tomato Leaf Images for Disease Analysis in Bangladesh," *Data in Brief*, vol. 59, p. 111327, Apr. 2025, doi: <https://doi.org/10.1016/j.dib.2025.111327>.
- [18] Md. J. A. Soeb *et al.*, "Tea Leaf Disease Detection and Identification Based on YOLOv7 (YOLO-T)," *Scientific Reports*, vol. 13, no. 1, p. 6078, Apr. 2023, doi: <https://doi.org/10.1038/s41598-023-33270-4>.

- [19] G. Divya, B. Mahender, G. Mahesh, and A. P. Kalyan, "AI-Powered Plant Health Assessment: Automated Classification for Enhanced Crop Monitoring and Productivity," *International Journal of Engineering Research and Science & Technology*, vol. 21, no. 3(1), pp. 40–46, Jul. 2025, doi: [https://doi.org/10.62643/ijerst.2025.v21.n3\(1\).pp40-46](https://doi.org/10.62643/ijerst.2025.v21.n3(1).pp40-46).
- [20] R. Sujatha, S. Krishnan, J. M. Chatterjee, and A. H. Gandomi, "Advancing Plant Leaf Disease Detection Integrating Machine Learning and Deep Learning," *Scientific Reports*, vol. 15, no. 1, p. 11552, Apr. 2025, doi: <https://doi.org/10.1038/s41598-024-72197-2>.
- [21] E. A. Aldakheel, M. Zakariah, and A. H. Alabdalall, "Detection and Identification of Plant Leaf Diseases Using YOLOv4," *Frontiers in Plant Science*, vol. 15, Apr. 2024, doi: <https://doi.org/10.3389/fpls.2024.1355941>.
- [22] T. Sultan *et al.*, "LeafDNet: Transforming Leaf Disease Diagnosis Through Deep Transfer Learning," *Plant Direct*, vol. 9, no. 2, Feb. 2025, doi: <https://doi.org/10.1002/pld3.70047>.
- [23] M. Bansal, A. Goyal, and A. Choudhary, "A Comparative Analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory Algorithms in Machine Learning," *Decision Analytics Journal*, vol. 3, p. 100071, Jun. 2022, doi: <https://doi.org/10.1016/j.dajour.2022.100071>.
- [24] V. Balafas, E. Karantoumanis, M. Louta, and N. Ploskas, "Machine Learning and Deep Learning for Plant Disease Classification and Detection," *IEEE Access*, vol. 11, pp. 114352–114377, 2023, doi: <https://doi.org/10.1109/ACCESS.2023.3324722>.
- [25] C. K. Sunil, C. D. Jaidhar, and N. Patil, "Systematic Study on Deep Learning-Based Plant Disease Detection or Classification," *Artificial Intelligence Review*, vol. 56, no. 12, pp. 14955–15052, Dec. 2023, doi: <https://doi.org/10.1007/s10462-023-10517-0>.
- [26] W. Shafik, A. Tufail, A. Namoun, L. C. De Silva, and R. A. A. H. M. Apong, "A Systematic Literature Review on Plant Disease Detection: Motivations, Classification Techniques, Datasets, Challenges, and Future Trends," *IEEE Access*, vol. 11, pp. 59174–59203, 2023, doi: <https://doi.org/10.1109/ACCESS.2023.3284760>.
- [27] W. B. Demilie, "Plant Disease Detection and Classification Techniques: A Comparative Study of the Performances," *Journal of Big Data*, vol. 11, no. 1, p. 5, Jan. 2024, doi: <https://doi.org/10.1186/s40537-023-00863-9>.
- [28] L. Tan, J. Lu, and H. Jiang, "Tomato Leaf Diseases Classification Based on Leaf Images: A Comparison Between Classical Machine Learning and Deep Learning Methods," *AgriEngineering*, vol. 3, no. 3, pp. 542–558, Jul. 2021, doi: <https://doi.org/10.3390/agriengineering3030035>.
- [29] D. J. Richter and K. Kim, "Assessing the Performance of Domain-Specific Models for Plant Leaf Disease Classification: A Comprehensive Benchmark of Transfer-Learning on Open Datasets," *Scientific Reports*, vol. 15, no. 1, p. 18973, May 2025, doi: <https://doi.org/10.1038/s41598-025-03235-w>.
- [30] S.-I. Sohn *et al.*, "Identification of *Amaranthus* Species Using Visible-Near-Infrared (Vis-NIR) Spectroscopy and Machine Learning Methods," *Remote Sensing*, vol. 13, no. 20, p. 4149, Oct. 2021, doi: <https://doi.org/10.3390/rs13204149>.
- [31] B. Olawoye, O. F. Fagbohun, O. Popoola-Akinola, J. E. T. Akinsola, and C. T. Akanbi, "A Supervised Machine Learning Approach for the Prediction of Antioxidant Activities of *Amaranthus viridis* Seed," *Heliyon*, vol. 10, no. 3, p. e24506, Feb. 2024, doi: <https://doi.org/10.1016/j.heliyon.2024.e24506>.
- [32] M. Strobel *et al.*, "An Evaluation Methodology for Machine Learning-Based Tandem Mass Spectra Similarity Prediction," *BMC Bioinformatics*, vol. 26, no. 1, p. 174, Jul. 2025, doi: <https://doi.org/10.1186/s12859-025-06194-1>.
- [33] K.-H. Huang *et al.*, "TextEE: Benchmark, Reevaluation, Reflections, and Future Challenges in Event Extraction," in *Findings of the Association for Computational Linguistics: ACL 2024*, Stroudsburg, PA, USA: Association for Computational Linguistics, 2024, pp. 12804–12825, doi: <https://doi.org/10.18653/v1/2024.findings-acl.760>.
- [34] B. J. Heil, M. M. Hoffman, F. Markowitz, S.-I. Lee, C. S. Greene, and S. C. Hicks, "Reproducibility Standards for Machine Learning in the Life Sciences," *Nature Methods*, vol. 18, no. 10, pp. 1132–1135, Oct. 2021, doi: <https://doi.org/10.1038/s41592-021-01256-7>.
- [35] S. V. S. Ramakrishnam Raju, B. Dappuri, P. Ravi Kiran Varma, M. Yachamaneni, D. M. G. Verghese, and M. K. Mishra, "Design and Implementation of Smart Hydroponics Farming Using IoT-Based AI Controller with Mobile Application System," *Journal of Nanomaterials*, vol. 2022, no. 1, Jan. 2022, doi: <https://doi.org/10.1155/2022/4435591>.
- [36] M. A. A. Ahmed and S. M. Reddy, "Smart Hydroponic System and Monitoring of Plant's Health Through Machine Learning," *International Journal for Research in Applied Science and Engineering Technology*, vol. 11, no. 6, pp. 4261–4263, Jun. 2023, doi: <https://doi.org/10.22214/ijraset.2023.54443>.
- [37] A. Abdalrahman *et al.*, "Efficient Plant Disease Detection Using Lightweight Deep Learning Model," *Journal of Intelligent Systems and Internet of Things*, vol. 16, no. 2, pp. 246–256, 2025, doi: <https://doi.org/10.54216/JISIoT.160218>.
- [38] S. Duhan, P. Gulia, N. S. Gill, and E. Narwal, "RTR_Lite_MobileNetV2: A Lightweight and Efficient Model for Plant Disease Detection and Classification," *Current Plant Biology*, vol. 42, p. 100459, Jun. 2025, doi: <https://doi.org/10.1016/j.cpb.2025.100459>.
- [39] Md. F. Ahamed, A. Salam, Md. Nahiduzzaman, M. Abdullah-Al-Wadud, and S. M. R. Islam, "Streamlining Plant Disease Diagnosis with Convolutional Neural Networks and Edge Devices," *Neural Computing and Applications*, vol. 36, no. 29, pp. 18445–18477, Oct. 2024, doi: <https://doi.org/10.1007/s00521-024-10152-y>.
- [40] A. T. Khan, S. M. Jensen, A. R. Khan, and S. Li, "Plant Disease Detection Model for Edge Computing Devices," *Frontiers in Plant Science*, vol. 14, Dec. 2023, doi: <https://doi.org/10.3389/fpls.2023.1308528>.
- [41] G. Idoje, T. Dagiuklas, and M. Iqbal, "On the Analysis of *Amaranthus viridis* Crop Growth Rate," *Computers and Electronics in Agriculture*, vol. 231, p. 109912, Apr. 2025, doi: <https://doi.org/10.1016/j.compag.2025.109912>.

BIOGRAFI PENULIS

Muhammad Ainul Fikri, S.T., M.Eng. merupakan dosen/peneliti di Politeknik Negeri Jember, Indonesia. Lulusan terakhir dari Universitas Gadjah Mada, Indonesia pada bidang Kecerdasan Buatan. Fokus penelitian meliputi Human Computer Interaction, Artificial Intelligence, Eye Tracking.

Iqbal Kurniawan Asmar Putra, S.Tr.T., M.Eng adalah dosen di Politeknik Negeri Padang, Indonesia. Menyelesaikan studi di Universitas Gadjah Mada dalam bidang artificial Intelligence. Fokus penelitian meliputi Machine Learning dan Deep Learning.

Apriska Prameswari, M.Si merupakan akademisi di Politeknik Negeri Padang, dengan latar belakang pendidikan terakhir di Universitas Andalas. Bidang keahlian elektronika dan kecerdasan buatan.

Puji Hastuti, S.T., M.Eng. merupakan dosen/peneliti di Politeknik Negeri Jember, Indonesia. Lulusan terakhir dari Universitas Gadjah Mada, Indonesia pada bidang Software Development. Fokus penelitian meliputi Software Development, Software testing and Quality Assurance, Human Computer Interaction.