

Penerapan Model EfficientNetB2 untuk Klasifikasi Citra Daun Tanaman Herbal

Dinda Friska Oktaviana¹

¹ Informatika, Universitas Pembangunan Nasional "Veteran" Jawa Timur

120081010121@student.upnjatim.ac.id

Abstrak— Penelitian ini menerapkan model EfficientNetB2 untuk mengklasifikasikan citra daun tanaman herbal yang terdiri atas sepuluh jenis daun. Jenis daun yang menjadi objek penelitian meliputi belimbing wuluh, jambu biji, jeruk nipis, kemangi, lidah buaya, nangka, pandan, pepaya, seledri, dan sirih. Dataset yang digunakan terdiri dari 350 citra per kelas yang diperoleh dari Mendeley Data dan 200 citra per kelas yang dikumpulkan secara mandiri, kemudian dibagi menjadi 80% data pelatihan dan 20% data pengujian. Teknik augmentasi data diterapkan untuk meningkatkan keragaman citra dan mencegah overfitting. Model EfficientNetB2 dilatih menggunakan dua variasi *learning rate* (0.001 dan 0.0001) serta dua jenis *optimizer* (Adam dan SGD) selama 30 *epoch*. Selain itu, ResNet50 digunakan sebagai model banding untuk mengevaluasi kinerja arsitektur utama. Berdasarkan hasil pengujian, konfigurasi terbaik diperoleh pada *learning rate* 0.001 dengan *optimizer* SGD, yang menghasilkan nilai akurasi pengujian sebesar 0.9927, presisi 0.9927, recall 0.9928, dan F1-score 0.9927. Hasil ini menunjukkan bahwa EfficientNetB2 memberikan performa yang sangat baik dalam tugas klasifikasi citra daun tanaman herbal serta unggul dibandingkan model banding.

Kata Kunci—EfficientNetB2, Klasifikasi Citra, Daun Herbal, CNN, Learning Rate

I. PENDAHULUAN

Indonesia memiliki kekayaan hayati yang melimpah, termasuk berbagai jenis tanaman berkhasiat obat, dan menempati posisi kedua terbesar di dunia setelah Brazil[1]. Bentuk obat tradisional di Indonesia sangat beragam, salah satunya adalah jamu. Seiring dengan perkembangan gaya hidup masyarakat, minat terhadap obat tradisional semakin meningkat karena dianggap lebih menyehatkan [2]. Bagian tanaman herbal yang paling sering digunakan sebagai bahan dasar obat tradisional adalah daunnya. Setiap jenis daun memiliki karakteristik morfologi yang khas, namun beberapa di antaranya memiliki kemiripan bentuk. Banyaknya jenis daun herbal sering kali menyebabkan kesalahan dalam proses identifikasi. Oleh karena itu, hal ini menjadi topik yang menarik untuk diteliti melalui pendekatan komputasional.

Berbagai metode dapat digunakan untuk melakukan klasifikasi citra daun tanaman herbal, salah satunya adalah deep neural network. Salah satu pendekatan yang termasuk dalam kategori ini adalah Convolutional Neural Network (CNN) [3]. Metode CNN dikenal memiliki kemampuan yang sangat baik dalam mengekstraksi fitur kompleks pada citra [4]. Di antara berbagai varian arsitektur CNN, terdapat EfficientNetB2 yang merupakan bagian dari keluarga EfficientNet.

Beberapa penelitian sebelumnya telah membuktikan efektivitas arsitektur EfficientNetB2 dalam tugas klasifikasi citra. Witjaksono dkk. pada Referensi [5] melaporkan bahwa penggunaan EfficientNetB2 dengan optimizer Adamax dan metode early stopping berhasil mencapai akurasi 100% pada data latih dan 99,59% pada data uji untuk klasifikasi batik bomba.

Selanjutnya, pada Referensi[6], EfficientNetB2 terbukti memberikan performa terbaik dalam mendeteksi penyakit pada buah peach, dengan rata-rata akurasi 96,6%, sensitivitas 90,5%, spesifisitas 98%, dan presisi 90,7% setelah dilakukan fine tuning, melampaui kinerja arsitektur lain seperti AlexNet dan ResNet50.

Selain itu, berdasarkan Referensi [7], penerapan EfficientNetB2 pada klasifikasi gambar tokoh wayang kulit menghasilkan akurasi 97,60% pada data latih, 97,72% pada validasi, dan 96,78% pada data uji. Jika dibandingkan dengan ResNet50 yang hanya mencapai akurasi tertinggi 95,92% pada data uji, EfficientNetB2 terbukti memiliki performa yang lebih unggul.

Berdasarkan berbagai penelitian terdahulu yang berhasil menerapkan EfficientNetB2 untuk tugas klasifikasi, dapat disimpulkan bahwa arsitektur ini menunjukkan kinerja yang unggul. Oleh sebab itu, penelitian ini memanfaatkan EfficientNetB2 untuk melakukan klasifikasi citra daun herbal Indonesia, dengan tujuan menilai sejauh mana performanya dalam konteks tersebut.

II. METODOLOGI

A. Studi Literatur

Pada tahap ini, penulis melakukan studi literatur dengan menelaah berbagai sumber seperti buku, jurnal ilmiah, dan artikel penelitian. Proses ini bertujuan untuk membangun dasar teori serta menjadi acuan dalam pemilihan dan penentuan kombinasi parameter yang digunakan dalam penelitian.

B. Pengumpulan Data

Tahap ini mencakup proses penyusunan dataset yang berisi sepuluh jenis daun herbal Indonesia, dengan masing-masing kelas terdiri atas 550 citra yang berasal dari data primer dan sekunder. Jenis daun yang digunakan meliputi belimbing wuluh, jambu biji, jeruk nipis, kemangi, lidah buaya, nangka, pandan, pepaya, seledri, dan sirih. Seluruh citra memiliki latar belakang putih dengan variasi pencahayaan untuk menambah keragaman visual. Data primer, dikumpulkan langsung oleh penulis di lingkungan sekitar tempat tinggal sebanyak 200 citra

per kelas. Adapun data sekunder diperoleh dari dataset publik di situs Mendeley Data yang digunakan pada penelitian sebelumnya[8] dengan jumlah 350 citra untuk setiap kelas.



Gbr. 1 Dataset Daun Herbal

C. Pengolahan Data

Dataset yang telah dikumpulkan akan melalui tahap pengolahan sebelum diimplementasikan pada model EfficientNetB2 maupun ResNet50. Tahap pengolahan tersebut meliputi penggabungan data primer dan sekunder untuk memperluas variasi sampel, kemudian dilakukan pembagian dataset menjadi 80% data pelatihan dan 20% data pengujian. Selanjutnya dilakukan augmentasi data, berupa random flip dan random rotation, yang berfungsi untuk meningkatkan keragaman citra sehingga model lebih tahan terhadap variasi bentuk dan orientasi daun.

D. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah arsitektur *deep learning* yang banyak digunakan untuk klasifikasi citra karena mampu mengekstraksi dan mempelajari pola visual secara otomatis. Struktur umum CNN mencakup lapisan konvolusi untuk mengekstraksi fitur, lapisan pooling untuk mereduksi dimensi dan kompleksitas komputasi, lapisan normalisasi untuk menstabilkan proses pelatihan, serta lapisan *fully-connected* yang melakukan pengambilan keputusan berdasarkan fitur yang telah dipelajari [9]. Proses pelatihan CNN dioptimalkan melalui penggunaan fungsi *loss* yang menyesuaikan bobot jaringan selama pembelajaran.

E. EfficientNetB2 dan ResNet50

Setelah dilakukan pengolahan data, dilakukan pembuatan model EfficientNetB2 dan ResNet50. EfficientNetB2 sendiri merupakan keluarga dari EfficientNet yang dirancang untuk meningkatkan efisiensi dan akurasi model melalui keseimbangan tiga aspek utama, yaitu kedalaman jaringan, lebar layer, dan resolusi citra masukan [10]. Arsitektur EfficientNetB2 terdiri atas tujuh blok utama yang tersusun dari kombinasi lapisan MBConv1 dan MBConv6, yang memungkinkan proses ekstraksi fitur berjalan secara lebih efektif dan terstruktur. Kemampuannya dalam memberikan kinerja yang tinggi dengan penggunaan sumber daya komputasi yang lebih efisien menjadi alasan pemilihan EfficientNetB2 sebagai model utama dalam penelitian ini.

Sementara itu, ResNet50 digunakan sebagai model pembanding. ResNet50 tersusun dari unit residual yang berlapis-lapis, di mana setiap unit residual memiliki shortcut connections yang menghubungkan keluaran suatu lapisan kembali ke lapisan sebelumnya[11]. Mekanisme shortcut ini membantu mengatasi masalah vanishing gradient, sehingga memungkinkan pelatihan jaringan yang lebih dalam tanpa menurunkan performa. Dengan demikian, ResNet50 dipilih sebagai pembanding untuk mengevaluasi perbandingan efektivitas arsitektur dalam tugas klasifikasi citra daun.

Implementasi model dilakukan setelah seluruh data selesai melalui tahap pra-pemrosesan. Proses fine-tuning dilakukan dengan membuka seluruh blok EfficientNetB2 maupun ResNet50 agar bobot jaringan dapat diperbarui secara menyeluruh sesuai dengan karakteristik citra daun tanaman herbal. Teknik transfer learning diterapkan dengan memanfaatkan bobot awal dari dataset ImageNet untuk meningkatkan akurasi model. Selanjutnya, ditambahkan lapisan Global Average Pooling dan Fully Connected Layer berupa dense layer dengan 10 neuron pada output, yang mewakili jumlah kelas daun herbal. Fungsi aktivasi softmax digunakan pada lapisan akhir untuk menghasilkan prediksi kelas dengan nilai probabilitas.

F. Pengujian dan Evaluasi

Pada tahap ini, model diuji menggunakan pembagian data sebesar 80% untuk pelatihan dan 20% untuk pengujian. Proses pelatihan dilakukan selama 30 epoch dengan ukuran batch 32 dan resolusi input 224×224 piksel, menggunakan dua optimizer yang berbeda yaitu Adam dan SGD dengan learning rate sebesar 0.001 dan 0.0001 untuk melihat pengaruh learning rate dan optimizer terhadap kinerja model. Setelah pelatihan selesai, kinerja model EfficientNetB2 dan ResNet50 dievaluasi untuk menilai tingkat efektivitasnya. Evaluasi tersebut mencakup pengukuran akurasi, presisi, recall, dan f1-score guna mengetahui kemampuan model dalam mengenali setiap kelas secara lebih mendalam.

III. HASIL DAN PEMBAHASAN

Berdasarkan hasil evaluasi yang disajikan pada Tabel 1, model EfficientNetB2 menunjukkan performa yang secara konsisten lebih unggul dibandingkan dengan model ResNet50 pada sebagian besar kelas daun ketika menggunakan optimizer Adam dengan learning rate 0.001.

TABEL 1
METRIK EVALUASI PENGUJIAN OPTIMIZER ADAM LEARNING RATE 0.001

Kelas	Rata-rata		
	Presisi	Recall	F1-score
Model EfficientNetB2			
Belimbing Wuluh	0.9882	0.9939	0.9909
Jambu Biji	0.9682	1.0000	0.9837
Jeruk Nipis	1.0000	0.9697	0.9846
Kemangi	0.9853	0.9970	0.9910
Lidah Buaya	1.0000	0.9667	0.9830
Nangka	1.0000	0.9727	0.9858
Pandan	0.9680	1.0000	0.9837
Pepaya	1.0000	0.9939	0.9969
Seledri	0.9910	0.9939	0.9924
Sirih	0.9910	1.0000	0.9955
Model ResNet50			
Belimbing Wuluh	0.9568	0.6811	0.7795
Jambu Biji	0.8350	0.9220	0.8556
Jeruk Nipis	0.8959	0.9106	0.8936
Kemangi	0.9115	0.8879	0.8909
Lidah Buaya	0.9544	0.9265	0.9384
Nangka	0.8764	0.9530	0.9054
Pandan	0.9685	0.8651	0.9127
Pepaya	0.9880	0.9909	0.9894
Seledri	0.9848	0.9856	0.9852
Sirih	0.8743	0.9190	0.8934

Kelas	Rata-rata		
	Presisi	Recall	F1-score
Model ResNet50			
Belimbing Wuluh	0.9568	0.6811	0.7795
Jambu Biji	0.8350	0.9220	0.8556
Jeruk Nipis	0.8959	0.9106	0.8936
Kemangi	0.9115	0.8879	0.8909
Lidah Buaya	0.9544	0.9265	0.9384
Nangka	0.8764	0.9530	0.9054
Pandan	0.9685	0.8651	0.9127
Pepaya	0.9880	0.9909	0.9894
Seledri	0.9848	0.9856	0.9852
Sirih	0.8743	0.9190	0.8934

Pada pengujian menggunakan optimizer SGD dengan learning rate 0.001 sebagaimana ditunjukkan pada Tabel 3, EfficientNetB2 kembali menunjukkan performa yang lebih unggul secara konsisten dibandingkan dengan ResNet50. Hal ini tercermin dari nilai presisi, recall, dan F1-score EfficientNetB2 yang sebagian besar berada pada rentang 0.9800 hingga 1.0000, bahkan mencapai nilai sempurna (1.0000) pada kelas Nangka. Pencapaian sempurna tersebut bukan berarti data mengalami leakage karena *splitting* data telah dilakukan sejak awal sehingga tidak terdapat tumpang tindih cintra antara data pelatihan maupun pengujian.

TABEL 3
METRIK EVALUASI PENGUJIAN OPTIMIZER SGD LEARNING RATE 0.001

Kelas	Rata-rata		
	Presisi	Recall	F1-score
Model EfficientNetB2			
Belimbing Wuluh	0.9880	1.0000	0.9940
Jambu Biji	0.9851	1.0000	0.9925
Jeruk Nipis	1.0000	0.9575	0.9783
Kemangi	0.9821	0.9970	0.9895
Lidah Buaya	1.0000	0.9818	0.9908
Nangka	1.0000	1.0000	1.0000
Pandan	0.9822	1.0000	0.9910
Pepaya	0.9970	1.0000	0.9985
Seledri	1.0000	0.9939	0.9969
Sirih	0.9940	0.9970	0.9955
Model ResNet50			
Belimbing Wuluh	0.9817	0.9757	0.9787
Jambu Biji	0.9434	0.9970	0.9693
Jeruk Nipis	0.9969	0.9576	0.9766
Kemangi	0.9881	0.9788	0.9833
Lidah Buaya	0.9910	0.9970	0.9940
Nangka	0.9910	0.9970	0.9940
Pandan	0.9970	0.9909	0.9939
Pepaya	1.0000	1.0000	1.0000
Seledri	1.0000	1.0000	1.0000

Selanjutnya pada hasil evaluasi yang ditunjukkan pada Tabel 4, model EfficientNetB2 tetap menunjukkan performa yang lebih unggul dibandingkan dengan model ResNet50 ketika menggunakan optimizer Adam dengan learning rate 0.0001. Hal ini terlihat dari nilai presisi, recall, dan F1-score EfficientNetB2 yang tinggi dan stabil pada seluruh kelas, dengan sebagian besar kelas mencapai nilai di atas 0.9800.

TABEL 2
METRIK EVALUASI PENGUJIAN OPTIMIZER ADAM LEARNING RATE 0.0001

Kelas	Rata-rata		
	Presisi	Recall	F1-score
Model EfficientNetB2			
Belimbing Wuluh	0.9882	0.9939	0.9909
Jambu Biji	0.9682	1.0000	0.9837
Jeruk Nipis	1.0000	0.9697	0.9846
Kemangi	0.9853	0.9970	0.9910
Lidah Buaya	1.0000	0.9667	0.9830
Nangka	1.0000	0.9727	0.9858
Pandan	0.9680	1.0000	0.9837
Pepaya	1.0000	0.9939	0.9969

Kelas	Rata-rata		
	Presisi	Recall	F1-score
Sirih	0.9940	0.9848	0.9893

Berdasarkan Tabel 4, ResNet50 menunjukkan performa yang sedikit lebih unggul, ditunjukkan oleh nilai presisi, recall, dan F1-score rata-rata yang lebih tinggi dibandingkan EfficientNetB2.

TABEL 4

METRIK EVALUASI PENGUJIAN OPTIMIZER SGD LEARNING RATE 0.0001

Kelas	Rata-rata		
	Presisi	Recall	F1-score
Model EfficientNetB2			
Belimbing Wuluh	0.9880	1.0000	0.9940
Jambu Biji	0.9851	1.0000	0.9925
Jeruk Nipis	1.0000	0.9575	0.9783
Kemangi	0.9821	0.9970	0.9895
Lidah Buaya	1.0000	0.9818	0.9908
Nangka	1.0000	1.0000	1.0000
Pandan	0.9822	1.0000	0.9910
Pepaya	0.9970	1.0000	0.9985
Seledri	1.0000	0.9939	0.9969
Sirih	0.9940	0.9970	0.9955
Model ResNet50			
Belimbing Wuluh	0.9817	0.9757	0.9787
Jambu Biji	0.9434	0.9970	0.9693
Jeruk Nipis	0.9969	0.9576	0.9766
Kemangi	0.9881	0.9788	0.9833
Lidah Buaya	0.9910	0.9970	0.9940
Nangka	0.9910	0.9970	0.9940
Pandan	0.9970	0.9909	0.9939
Pepaya	1.0000	1.0000	1.0000
Seledri	1.0000	1.0000	1.0000
Sirih	0.9940	0.9848	0.9893

Selanjutnya, dilakukan perbandingan rata-rata performa antara kedua pengujian untuk menentukan hasil terbaik. Nilai rata-rata akurasi, presisi, recall, dan f1-score dari masing-masing pengujian ditampilkan pada Tabel 5. Berdasarkan Tabel tersebut, dapat dilihat bahwa EfficientNetB2 secara konsisten menunjukkan performa yang lebih tinggi dibandingkan ResNet50 pada kedua nilai learning rate yang diuji menggunakan optimizer Adam. Pada learning rate 0.001, EfficientNetB2 memperoleh rata-rata akurasi, presisi, recall, dan F1-score yang lebih baik dibandingkan ResNet50. Kemudian ketika learning rate diturunkan menjadi 0.0001, peningkatan performa EfficientNetB2 menjadi lebih signifikan, dengan nilai rata-rata yang mencapai sekitar 0.99. Sementara itu, ResNet50 tidak menunjukkan peningkatan yang sebanding pada konfigurasi yang sama.

TABEL 5

RATA-RATA METRIK EVALUASI PENGUJIAN OPTIMIZER ADAM

Model	Rata-rata			
	Presisi	Recall	F1-score	Akurasi
Learning Rate 0.001				
EfficientNetB2	0.9690	0.9448	0.9452	0.9448
ResNet50	0.9245	0.9041	0.9043	0.9015
Learning Rate 0.0001				
EfficientNetB2	0.9891	0.9887	0.9887	0.9887
ResNet50	0.9490	0.8975	0.9050	0.8975

Sementara itu, pada pengujian menggunakan optimizer SGD, EfficientNetB2 menunjukkan performa yang lebih unggul dibandingkan ResNet50 pada learning rate 0.001, dengan nilai presisi, recall, F1-score, dan akurasi yang berada pada kisaran 0.99. Namun, ketika learning rate diturunkan menjadi 0.0001, performa EfficientNetB2 mengalami penurunan yang cukup signifikan, sehingga ResNet50 menjadi model yang lebih baik pada konfigurasi tersebut. Rincian perbedaan nilai metrik dari kedua model dapat dilihat pada Tabel 2.

TABEL 6
RATA-RATA METRIK EVALUASI PENGUJIAN OPTIMIZER SGD

Model	Rata-rata			
	Presisi	Recall	F1-score	Akurasi
Learning Rate 0.001				
EfficientNetB2	0.9928	0.9927	0.9927	0.9927
ResNet50	0.9883	0.9878	0.9879	0.9878
Learning Rate 0.0001				
EfficientNetB2	0.9419	0.9394	0.9395	0.9394
ResNet50	0.9831	0.9824	0.9824	0.9824

IV. KESIMPULAN

Penelitian ini membuktikan bahwa arsitektur EfficientNetB2 merupakan solusi yang efektif untuk tugas klasifikasi citra daun tanaman herbal. Dengan menerapkan transfer learning pada model EfficientNetB2 yang sebelumnya telah dilatih menggunakan dataset ImageNet, serta didukung oleh teknik augmentasi data, model mampu mengenali dan mempelajari karakteristik visual tiap daun secara optimal. Proses pelatihan dilakukan selama 30 epoch dengan dua skenario learning rate (0.001 dan 0.0001) serta dua jenis optimizer, yaitu Adam dan SGD.

Berdasarkan hasil pengujian, EfficientNetB2 menunjukkan performa yang unggul dibandingkan ResNet50 pada sebagian besar konfigurasi. Pada pengujian menggunakan optimizer Adam, EfficientNetB2 menghasilkan nilai rata-rata presisi, recall, F1-score, dan akurasi yang lebih tinggi daripada ResNet50 untuk kedua learning rate yang digunakan. Kinerja terbaik diperoleh pada konfigurasi learning rate 0.0001, di mana EfficientNetB2 mencapai akurasi rata-rata 0.9887, sedangkan ResNet50 hanya mencapai 0.8975.

Sementara itu, pengujian dengan optimizer SGD, EfficientNetB2 tetap lebih unggul pada *learning rate* 0.001 dengan akurasi rata-rata 0.9927, sedikit lebih tinggi dibandingkan ResNet50 yang memperoleh akurasi 0.9878. Namun, pada *learning rate* 0.0001 terjadi penurunan performa EfficientNetB2 sehingga ResNet50 berkinerja lebih baik dengan akurasi 0.9824, sementara EfficientNetB2 memperoleh 0.9394.

Secara keseluruhan, hasil penelitian menunjukkan bahwa EfficientNetB2 memiliki kemampuan generalisasi dan ekstraksi fitur yang lebih baik dalam klasifikasi daun herbal, khususnya ketika dikombinasikan dengan optimizer Adam dan pengaturan *learning rate* yang tepat. Hal ini mengindikasikan bahwa EfficientNetB2 dapat digunakan sebagai model dasar yang andal untuk sistem identifikasi daun herbal otomatis.

REFERENSI

- [1] D. Darmin et al., “Upaya Pemberdayaan Masyarakat Melalui Apotek Hidup: Pemanfaatan Tanaman Obat Untuk Kesehatan dan Konservasi Keanekaragaman Hayati,” *Jurnal Pengabdian kepada Masyarakat Nusantara*, vol. 5, no. 4, pp. 5151–5158, 2024.
- [2] M. M. Al Haromainy, “Pelatihan Pengolahan Rempah Sebagai Minuman Herbal Instan Di Lingkungan Pondok Pesantren,” *Jurnal Inovasi Pengabdian Masyarakat*, vol. 3, no. 2, 2023.
- [3] M. F. Novriandy, B. Rahmat, and A. Junaidi, “Klasifikasi Citra Penyakit Kanker Mulut Menggunakan Arsitektur Resnet50 Optimasi Adam Dan Sgd,” *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, 2024.
- [4] R. A. Ramadhani, B. W. Pangestu, and R. Purbaningtyas, “Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network Dengan Arsitektur Efficientnet-B3,” *JUST IT: Jurnal Sistem Informasi, Teknologi Informasi dan Komputer*, vol. 12, no. 3, pp. 55–59, 2022.
- [5] J. Witjaksono, M. Y. Pusadan, Y. Anshori, R. Ardiansyah, and R. Azhar, “KLASIFIKASI JENIS BATIK BOMBA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR EFFICIENT-NET B2 (BATIK BOMBA SULAWESI TENGAH),” *JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 10, no. 3, pp. 2134–2147, 2025.
- [6] H. Farman, J. Ahmad, B. Jan, Y. Shahzad, M. Abdullah, and A. Ullah, “Efficientnet-based robust recognition of peach plant diseases in field images,” *Comput. Mater. Contin.*, vol. 71, no. 1, pp. 2073–2089, 2022.
- [7] H. K. Maulana, “PENERAPAN ARSITEKTUR CNN-EFFICIENTNETB2 DENGAN TRANSFER LEARNING PADA KLASIFIKASI GAMBAR TOKOH WAYANG KULIT,” *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 1, 2025.
- [8] A. E. W. G. W. A. Y. H. M. Y. Minarno, “Indonesian Herb Leaf Dataset 3500,” Mendeley Data. Accessed: Oct. 24, 2024. [Online]. Available: 10.17632/s82j8dh4rr.1
- [9] S. Arnandito and T. B. Sasongko, “Comparison of EfficientNetB7 and MobileNetV2 in Herbal Plant Species Classification Using Convolutional Neural Networks,” *Journal of Applied Informatics and Computing*, vol. 8, no. 1, pp. 176–185, 2024.
- [10] M. Harahap and A. M. Husein, “Penerapan Efficient-Net Dalam Mengklasifikasi Kanker Kulit,” *PUBLIS PENERBIT UNPRI PRESS*, vol. 1, no. 1, 2024.
- [11] Ü. Atila, M. Uçar, K. Akyol, and E. Uçar, “Plant leaf disease classification using EfficientNet deep learning model,” *Ecol Inform*, vol. 61, p. 101182, 2021.