

Deteksi Daun Herbal Berbasis Android Menggunakan Transfer Learning MobileNetV2

Raya Osgibran¹

¹Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: [*rayaosgibran30@gmail.com](mailto:rayaosgibran30@gmail.com),

Abstrak – Negara Indonesia adalah negara yang kaya akan tanaman herbal, namun sering kali sulit membedakannya karena banyak daun yang bentuknya mirip saat melakukan identifikasi gambar otomatis. Riset ini berupaya menciptakan alat pendeteksi daun obat dengan memakai rancangan MobileNetV2 melalui Transfer Learning di platform Android. Data latih penelitian ini berisi 3.500 foto daun obat yang terbagi rata ke dalam 10 jenis untuk proses belajar, pengecekan, dan pengujian. Proses belajar model di studi ini mencapai akurasi cek sebesar 99.43%, menandakan adanya sedikit kecenderungan overfitting. Namun, saat diuji coba, akurasinya mencapai 74.24%, memperlihatkan kemampuan adaptasi yang lebih baik dibandingkan riset sebelumnya memakai Inception V3. Kekeliruan klasifikasi yang paling parah terjadi pada daun yang bentuk fisiknya sangat mirip satu sama lain. Selanjutnya, model ini diwujudkan dalam aplikasi Android yang mampu menggolongkan daun obat tanpa koneksi internet dan bekerja lancar, ditambah nilai keyakinan untuk menekan potensi salah tebak positif, serta memaparkan manfaat medis setiap daun yang teridentifikasi berdasarkan referensi literatur dari Kementerian Kesehatan Republik Indonesia. Temuan riset ini menegaskan bahwa MobileNetV2 dengan transfer learning memang efektif dipakai sebagai deteksi daun obat di perangkat Android dengan komputasi minim.

Kata Kunci — Android, daun herbal, MobileNetV2, computer vision.

1. PENDAHULUAN

Indonesia memang terkenal punya kekayaan hayati yang sangat melimpah, termasuk beragam tanaman untuk jamu. Sejak dulu, nenek moyang kita sudah memanfaatkan tanaman herbal sebagai pengobatan alami untuk menjaga badan tetap sehat dan menyembuhkan bermacam penyakit. Akan tetapi, masalah besar yang sering dihadapi banyak orang adalah kesulitan menentukan secara pasti tanaman herbal yang benar, sebab banyak tanaman punya daun yang mirip sekali dari segi rupa, sentuhan, serta corak warnanya. Jika salah mengidentifikasi tanaman, dampaknya bisa berbahaya atau malah mengurangi manfaat obatnya. Oleh karena itu, teknologi yang mengandalkan kecerdasan buatan, khususnya bidang Computer Vision, muncul sebagai jalan keluar yang sangat diperlukan guna menolong proses identifikasi ini secara otomatis dan bisa langsung terlihat.

Banyak penelitian terdahulu sudah memanfaatkan formula kecerdasan buatan untuk memilah tumbuh tumbuhan. [1] menerapkan cara Backpropagation dengan mengambil ciri warna dan corak permukaan untuk mengenali daun jambu air, tetapi keakuratan yang diraih baru mencapai 80%, menandakan keterbatasan cara konvensional saat berhadapan dengan perbedaan gambar yang pelik. Kemudian, [2] merancang tata cara "Herbify" yang berjalan di cloud dengan struktur Xception dan sukses mencapai ketepatan 96,3%. Strategi berbasis ponsel juga diterapkan oleh [3] yang membuat aplikasi guna memperkirakan tanaman obat memakai Jaringan Saraf Tiruan Berlapis (CNN) dan memperoleh akurasi pengujian sebesar 96,67%.


Meskipun hasil akurasi pada beragam penelitian itu lumayan bagus, kendala masih muncul mengenai ketahanan model (kemampuannya untuk digeneralisasi) dan kinerja pada ponsel pintar. Kendala ini amat tampak dalam riset terkini dari [4] yang memakai rancangan Inception V3 untuk mengidentifikasi daun tanaman obat. Riset itu memperlihatkan jurang perbedaan lebar antara ketepatan saat pelatihan yang menyentuh 93,99% dengan ketepatan saat pengujian yang anjlok tajam hingga 51,67%. Kondisi terlalu pas ini menandakan bahwa sistem tersebut gagal mengidentifikasi informasi baru secara memadai, mungkin sebab tingkat kerumitan desain sistemnya kurang sesuai dengan keragaman yang ada di kumpulan data.

Guna menangani isu berlebih muatan dan kebutuhan akan rancangan yang tidak membebani pada ponsel pintar, penelitian ini menyarankan penggunaan desain MobileNetV2 dengan Pembelajaran Transfer. MobileNetV2 dipilih karena memanfaatkan blok residual terbalik yang hemat daya hitung seraya mempertahankan capaian yang memuaskan. Kajian ini berupaya menciptakan perangkat pendeteksi daun obat di Android yang tidak hanya tepat saat pemrosesan awal, namun juga punya kekuatan menyesuaikan diri yang

solid pada data pengujian, serta dapat menyajikan keterangan terkait khasiat medis yang sudah dipastikan kepada pemakai.

2. METODE PENELITIAN

Alur penelitian ini dirancang menggunakan standar *Cross-Industry Standard Process for Data Mining* (CRISP-DM). Metode ini terdiri dari enam tahapan siklus hidup pengembangan data mining, yaitu: *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*. Kerangka kerja ini dipilih karena mampu menjamin validitas model yang dihasilkan serta kemudahan integrasi ke dalam sistem aplikasi *mobile*.



Gambar 1. Tahapan Penelitian Menggunakan Metode CRISP-DM [5].

dibawah ini adalah penjelasan detail dari tahapan prosedur penelitian diatas:

2.1 Pemahaman Masalah

Fase ini fokus pada penetapan apa saja yang dibutuhkan oleh sistem tersebut. Kendala paling besar yang kami lihat adalah orang biasa kesulitan membedakan tampilan daun tanaman obat karena bentuknya yang hampir sama persis kalau dilihat. Riset ini bertujuan membuat rancangan untuk menggolongkan gambar yang tidak hanya akurat, namun juga cepat saat diproses (tidak berat) agar bisa jalan langsung di HP Android yang keterbatasan dayanya.

2.2 Pengumpulan Data

Informasi yang digunakan dalam kajian ini bersumber dari penyimpanan data umum Mendeley Data dengan judul "Indonesian Herb Leaf Dataset 3500," seperti yang dipublikasikan oleh [11]. Pilihan jatuh pada set data ini sebab ia menggambarkan kayanya ragam makhluk hidup tropis di nusantara. Strategi mengenali lewat foto daun dipilih lantaran punya beberapa keunggulan; daun bisa ditemui kapan saja, gampang diperoleh, serta proses pengambilannya lebih kecil risikonya melukai tanaman dibanding bila mengambil akar atau batangnya.

Set data ini memuat total 3.500 foto digital berformat .jpg dengan mutu bagus (resolusi 1600 kali 1200 piksel). Seluruh foto direkam di atas alas putih supaya mengurangi halangan pandangan dan memudahkan proses penarikan ciri. Set data ini punya pembagian spesies yang merata, mencakup sepuluh macam tanaman obat, di mana setiap jenis memiliki 350 foto.

Kesepuluh jenis tanaman ini ditetapkan tidak hanya sebab tumbuh di Indonesia, namun juga karena khasiat kesehatannya yang sudah teruji baik secara ilmiah maupun dari pengalaman. Dasar pertimbangan khasiat obat tanaman dalam studi ini mengacu pada Formularium Ramuan Obat Tradisional Indonesia dari Kemenkes RI [6] dan sejumlah telah pustaka terhangat [7], [8], [9]. Detail tentang set data, nama ilmiah, serta kegunaan utama dari setiap tumbuhan ditampilkan dalam Tabel 1.

Tabel 1. Rincian Kelas Dataset Daun Herbal dan Referensi Manfaat Medis

No	Nama Tanaman	Nama Latin	Manfaat
1	Belimbing Wuluh	<i>Averrhoa bilimbi L.</i>	Mengobati jerawat dan anti-hipertensi [6]
2	Jambu Biji	<i>Psidium guajava</i>	Mengobati diare dan meningkatkan trombosit [6]
3	Jeruk Nipis	<i>Citrus aurantifolia</i>	Meredakan batuk dan nyeri haid [6]
4	Kemangi	<i>Ocimum basilicum</i>	Menghilangkan bau mulut dan antibakteri [6]
5	Lidah Buaya	<i>Aloe vera</i>	Menyembuhkan luka bakar ringan dan radang [6]
6	Nangka	<i>Artocarpus heterophyllus</i>	Membantu mempercepat penyembuhan luka bakar dan antibakteri [9]
7	Pandan	<i>Pandanus amaryllifolius</i>	meredakan nyeri, mempercepat penyembuhan luka, serta mendukung kesehatan kulit dan sistem kardiovaskular [8]
8	Pepaya	<i>Carica papaya L.</i>	Penambah nafsu makan dan obat demam [6]
9	Seledri	<i>Apium graveolens</i>	Anti-inflamasi dan mencegah penyakit radang [7]
10	Sirih	<i>Piper betle</i>	Menghentikan mimisan dan antiseptik [6]

2.3 Pra-pemrosesan Data


Sebelum data dimasukkan ke sistem, terdapat langkah penyiapan yang harus dilakukan supaya model bisa bekerja lebih baik yaitu:

1. Resize: Foto diperkecil ukurannya menjadi 224×224 piksel, sesuai dengan ukuran standar yang dibutuhkan oleh kerangka MobileNetV2.
2. Normalisasi: Nilai piksel diubah menjadi bentuk standar ImageNet untuk mempercepat proses konvergensi model.
3. Augmentasi Data: Untuk menghindari *Overfitting* model, metode augmentasi digunakan pada set data pelatihan, termasuk rotasi acak, pembalikan secara horizontal, dan pengaturan kecerahan.
4. Pembagian Data: Dataset dibagi menjadi tiga bagian: 70% untuk data latih (*training*), 20% untuk validasi (*validation*), dan 10% untuk pengujian (*testing*).

2.4 Pemodelan

Pada tahap ini model klasifikasi dibangun dengan memanfaatkan teknik Transfer Learning yang menggunakan arsitektur MobileNetV2. Model ini dipilih karena memang dirancang untuk perangkat mobile yang punya keterbatasan daya olah dan ruang simpan, namun tetap mampu menghasilkan tingkat ketepatan yang baik. Hal utama yang membuat MobileNetV2 unik dibanding arsitektur lain adalah penggunaan blok Inverted Residuals dan Linear Bottlenecks. Berdasarkan [10], truktur ini dibuat untuk menangani persoalan hilangnya data pada lapisan yang tidak linear (ReLU) saat dimensinya kecil.

1. Inverted Residuals: Dalam desain arsitektur konvensional seperti ResNet, bagian residual menjalankan alur kerja "Wide \rightarrow Narrow \rightarrow Wide" (dimensi besar diperkecil, lalu dikembalikan ke besar lagi). Berbeda dengan itu, MobileNetV2 membalik urutan menjadi "Narrow \rightarrow Wide \rightarrow Narrow" (dimensi kecil diekspansi ke besar, lalu diperkecil kembali). Proses ekspansi dilakukan melalui *Depthwise convolution* guna mendapatkan detail fitur secara mendalam namun dengan kebutuhan daya hitung yang rendah
2. Linear Bottlenecks: Pada lapisan akhir dari blok *Inverted Residual*, fungsi aktivasi non-linear (seperti ReLU) dihilangkan dan diganti dengan fungsi linear. Hal ini bertujuan untuk mempertahankan keragaman informasi (*representational power*) yang telah dipelajari model, karena penggunaan ReLU pada dimensi rendah (bottleneck) terbukti dapat menghancurkan informasi penting.



Gambar 2. Perbandingan blok *Residual* standar (kiri) dengan blok *Inverted Residual* MobileNetV2 (kanan).

MobileNetV2 menghubungkan lapisan *bottleneck* (tipis) secara langsung, berbeda dengan ResNet yang menghubungkan lapisan ekspansi (tebal) [10]. Perbedaan mendasar struktur blok ini dapat dilihat pada Gambar 2 yang diadopsi dari artikel referensi [10]. Untuk keperluan klasifikasi daun herbal, lapisan klasifikasi (*classifier*) asli dari MobileNetV2 yang terdiri dari 1000 neuron (ImageNet) dimodifikasi. Lapisan *Fully Connected Layer* diganti dengan lapisan baru yang memiliki 10 *output neuron*, sesuai dengan jumlah kelas tanaman herbal dalam penelitian ini. Fungsi aktivasi *Softmax* digunakan pada lapisan terakhir untuk menghasilkan probabilitas prediksi bagi setiap kelas.

2.5 Evaluasi


Model yang telah dilatih dievaluasi menggunakan data uji (*testing set*) yang belum pernah dilihat sebelumnya oleh model. Metrik evaluasi yang digunakan meliputi:

1. *Accuracy*: Seberapa akurat prediksi keseluruhan.
2. *Precision*, *Recall*, dan *F1-Score*: Untuk melihat seberapa baik performa model pada masing-masing jenis daun.
3. *Confusion Matrix*: Untuk memetakan persebaran prediksi benar dan salah antar kelas.

2.6 Implementasi

Langkah terakhir yaitu menerapkan model yang sudah dilatih ke dalam aplikasi Mobile yang menggunakan sistem operasi Android. Pekerjaan ini meliputi perubahan model dari format PyTorch yaitu .pth ke format TorchScript yakni .pt yang sudah disesuaikan agar cocok untuk Mobile. Aplikasi tersebut dibuat memakai bahasa pemrograman Kotlin di lingkungan Android Studio. Tampilan aplikasi dibuat praktis supaya pengguna mudah untuk memakainya, di mana perangkat akan mengambil gambar lewat kamera, memprosesnya langsung di ponsel (tanpa koneksi internet) dan segera menunjukkan nama daun beserta khasiat kesehatannya.

3. HASIL DAN PEMBAHASAN




Gambar 3. Grafik Pergerakan Akurasi dan Loss pada Data Latih dan Validasi

Proses pelatihan model dilakukan menggunakan skenario hiperparameter yang telah ditentukan pada tahap metode penelitian, yaitu ukuran citra input 224×224 piksel, ukuran batch 12, dan total durasi pelatihan selama 50 epoch. Pelatihan memakan waktu total sekitar 4 jam 8 menit (dimulai pukul 12:04 hingga 16:12) menggunakan

akselerasi GPU. Secara kuantitatif, hasil pelatihan menunjukkan performa yang sangat signifikan sejak tahap awal. Pada *Epoch* ke-1, model langsung mencapai akurasi validasi sebesar 90,71% dengan *validation loss* 0,4720. Tingginya akurasi awal ini membuktikan efektivitas teknik *Transfer Learning*. Bobot *pre-trained* dari MobileNetV2 (yang telah dilatih pada ImageNet) mampu mengekstraksi fitur dasar daun dengan sangat baik meskipun baru satu kali putaran pelatihan.


Kinerja model terus meningkat secara konsisten hingga mencapai puncaknya pada *Epoch* ke-20. Pada titik ini, model mencatat Akurasi Validasi Tertinggi (*Best Validation Accuracy*) sebesar 99,43% dengan nilai *loss* validasi yang sangat rendah yaitu 0,0334. Angka ini menunjukkan bahwa model telah mempelajari pola fitur daun herbal dengan sangat presisi. Setelah mencapai puncak di *Epoch* 20, performa model cenderung stabil di kisaran 98% - 99% hingga akhir pelatihan di *Epoch* 50. Penurunan *Learning Rate* (LR) secara otomatis dari 1×10^{-4} pada awal pelatihan menjadi 3.9×10^{-7} di akhir pelatihan berperan penting dalam menjaga stabilitas ini. Penyesuaian LR yang semakin kecil memungkinkan model untuk melakukan *fine-tuning* bobot secara halus dan mencegah osilasi nilai *loss* saat mendekati titik minimum global.

Berdasarkan visualisasi grafik pada Gambar 3, terlihat kurva "Good Fit" di mana garis akurasi pelatihan (*training accuracy*) dan validasi (*validation accuracy*) bergerak beriringan naik dan berhimpitan rapat. Pada Akurasi tidak terdapat celah (*gap*) yang lebar antara akurasi latih dan validasi, yang mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* maupun *underfitting*. Pada *Loss* kurva *loss* menurun secara tajam pada 5 *epoch* pertama dan melandai mendekati nol setelah *epoch* ke-15. Fenomena di mana *validation loss* terkadang lebih rendah daripada *training loss* (seperti pada *Epoch* 1-5) adalah wajar dalam penerapan augmentasi data, karena data validasi bersifat "bersih" (tanpa rotasi/distorsi) sehingga lebih mudah diprediksi oleh model dibandingkan data latih yang diaugmentasi.



Gambar 4. Sampel hasil prediksi model pada data uji

Untuk memvalidasi kinerja model secara visual, dilakukan pengambilan sampel acak dari data uji untuk melihat perbandingan antara label asli (*Target*) dan label hasil prediksi model (*Prediction*). Sebagaimana terlihat pada Gambar 4, model mampu memprediksi kelas tanaman dengan tepat, seperti pada sampel daun Seledri, Sirih, dan Kemangi. Kesesuaian antara label *Target* (T) dan *Prediksi* (P) menunjukkan bahwa model telah berhasil mengekstraksi fitur visual unik dari setiap jenis daun herbal, meskipun terdapat kemiripan warna dan bentuk yang signifikan antar kelas.



Gambar 5. Confusion Matrix

Pada Gambar 5 ditunjukkan *confusion matrix* hasil klasifikasi sepuluh kelas daun dengan akurasi keseluruhan sebesar 78,24%. Sebagian besar prediksi benar berada pada diagonal utama, khususnya pada kelas Jeruk Nipis, Pandan, Pepaya, Seledri, dan Sirih, yang menunjukkan bahwa model mampu mengenali kelas dengan ciri visual yang khas secara konsisten. Namun demikian, kesalahan klasifikasi masih terlihat pada beberapa kelas, terutama Belimbing Wuluh dan Kemangi. Kedua kelas tersebut sering diprediksi sebagai kelas lain, yang mengindikasikan adanya kemiripan karakteristik visual antar daun sehingga menyulitkan model dalam melakukan pemisahan fitur secara akurat.


Tabel 2. Laporan statistik Klasifikasi

No	Nama Kelas	Precision	Recall	F1 scores
1	Belimbing Wuluh	1.00	0.35	0.52
2	Jambu Biji	0.74	1.00	0.85
3	Jeruk Nipis	0.90	1.00	0.95
4	Kemangi	1.00	0.10	0.18
5	Lidah Buaya	1.00	0.40	0.57
6	Nangka	0.84	0.80	0.82
7	Pandan	0.71	1.00	0.83
8	Pepaya	0.69	1.00	0.82
9	Seledri	1.00	1.00	1.00
10	Sirih	0.56	1.00	0.71

Pada Tabel 2 disajikan nilai *precision*, *recall*, dan *F1-score* untuk setiap kelas. Kelas Jeruk Nipis dan Seledri menunjukkan performa terbaik dengan nilai *recall* dan *F1-score* yang tinggi. Sebaliknya, kelas Kemangi memiliki nilai *recall* yang sangat rendah (0,10), meskipun *precision* tinggi, yang menandakan bahwa sebagian besar sampel kelas tersebut gagal terdeteksi oleh model. Secara keseluruhan, model memperoleh macro-average F1-score sebesar 0,73 dan weighted-average F1-score sebesar 0,74, menunjukkan bahwa performa model belum merata pada seluruh kelas. Hasil ini mengindikasikan bahwa peningkatan performa selanjutnya perlu difokuskan pada kelas dengan kemiripan visual tinggi melalui penambahan data dan optimasi strategi ekstraksi fitur.



Gambar 6. Tampilan halaman utama aplikasi



Gambar 7. Tampilan hasil klasifikasi

Pada Gambar 6 ditampilkan antarmuka utama aplikasi yang menyediakan satu tombol utama, yaitu tombol untuk memulai proses klasifikasi menggunakan kamera pada perangkat smartphone. Pengguna dapat mengambil citra daun secara langsung melalui kamera untuk selanjutnya diproses oleh sistem. Pada Gambar 7 ditunjukkan hasil citra yang telah diambil beserta keluaran prediksi model, yang meliputi nama daun hasil identifikasi dan nilai *confidence score*. Untuk meningkatkan keandalan sistem, diterapkan ambang batas (*threshold*) kepercayaan, di mana apabila nilai *confidence score* $\leq 50\%$, maka hasil prediksi akan ditampilkan sebagai *null*. Mekanisme ini bertujuan untuk mencegah kesalahan klasifikasi terhadap objek selain daun atau objek yang berada di luar dataset pelatihan. Selain hasil identifikasi, aplikasi juga menampilkan informasi mengenai manfaat medis dari daun yang terdeteksi. Informasi tersebut diperoleh berdasarkan kajian literatur yang dirujuk pada sumber [7], [8], [9], dan [4].

4. SIMPULAN

Berdasarkan hasil penelitian, model MobileNetV2 dengan pendekatan transfer learning mampu mencapai akurasi validasi tertinggi sebesar 99,43% pada tahap pelatihan. Pada tahap pengujian menggunakan data yang belum pernah dilihat sebelumnya, model memperoleh akurasi sebesar 78,24%. Selisih performa antara tahap pelatihan dan pengujian menunjukkan adanya indikasi overfitting ringan. Hasil evaluasi menunjukkan bahwa kesalahan klasifikasi paling banyak terjadi pada kelas daun yang memiliki kemiripan morfologi visual tinggi, khususnya Kemangi dan Belimbing Wuluh. Model berhasil diimplementasikan ke dalam aplikasi Android dan dapat melakukan klasifikasi secara offline. Sistem dilengkapi dengan mekanisme ambang batas kepercayaan sebesar 50% untuk mengurangi prediksi pada objek di luar dataset, serta menampilkan informasi manfaat medis daun berdasarkan literatur yang digunakan dalam penelitian.

5. SARAN

Untuk pengembangan selanjutnya, disarankan perluasan dan diversifikasi dataset guna meningkatkan kemampuan model dalam membedakan daun yang memiliki kemiripan visual. Selain itu, peningkatan performa dapat dilakukan melalui *fine-tuning* lanjutan atau penggunaan arsitektur lightweight yang lebih baru. Penerapan pra-pemrosesan dan augmentasi citra yang lebih lanjut serta pengembangan fitur deteksi real-time berbasis video juga direkomendasikan guna meningkatkan akurasi dan kenyamanan penggunaan aplikasi.

DAFTAR PUSTAKA

- [1] E. Anggraini and N. Nafiiyah, "Klasifikasi Jenis Daun Jambu Air dengan Backpropagation."
- [2] A. Tirtana, M. Gita, T. Febriani, D. I. Masrui, and A. A. Aisyah, "Herbify: Aplikasi Perangkat Bergerak Berbasis Komputasi Awan Untuk Mengidentifikasi Tanaman Herbal Indonesia Menggunakan Cnn Model Xception," 2021.
- [3] A. Kurnia, S. Yuda, and A. Setiadi, "Implementasi Prediksi Tanaman Herbal Menggunakan Algoritma Convolutional Neural Network Berbasis Android," 2023. [Online]. Available: <https://ejournal.bsi.ac.id/ejurnal/index.php/reputasi84>
- [4] H. Kamilia Zulfiani and A. Abdullah, "IDENTIFIKASI DAUN HERBAL UNTUK TANAMAN OBAT MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)," 2025.

-
- [5] I. N. Switrayana, D. Ashadi, H. Hairani, and A. Aminuddin, "Sentiment Analysis and Topic Modeling of Kitabisa Applications using Support Vector Machine (SVM) and Smote-Tomek Links Methods," *International Journal of Engineering and Computer Science Applications (IJECSA)*, vol. 2, no. 2, pp. 81–91, Sep. 2023, doi: 10.30812/ijecca.v2i2.3406.
- [6] Kementerian Kesehatan Republik Indonesia, "Keputusan Menteri Kesehatan Republik Indonesia Nomor HK.01.07/MENKES/187/2017 tentang Formularium Ramuan Obat Tradisional Indonesia," Jakarta: Kementerian Kesehatan RI, 2017.
- [7] D. Liu, H. Zhao, H. Xu, and J. Hu, "Effects of celery (*Apium graveolens*) on blood pressure, glycemic and lipid profile in adults: a systematic review and meta-analysis of randomized controlled trials," 2025, *Frontiers Media SA*. doi: 10.3389/fnut.2025.1597680.
- [8] P. P. Adkar and V. H. Bhaskar, "Pandanus odoratissimus (Kewda): A review on ethnopharmacology, phytochemistry, and nutritional aspects," 2014, *Hindawi Publishing Corporation*. doi: 10.1155/2014/120895.
- [9] M. Erista Magdalena, S. Yolandari, S. Supardi, and P. Baubau, "EFFECTIVENESS OF BURN WOUND HEALING FROM JACKFRUIT LEAF ETHANOL EXTRACT (*Artocarpus Heterophyllus* L.) ON MALE WHITE RATS (*Rattus Norvegicus*)," 2024.
- [10] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," Mar. 2019, [Online]. Available: <http://arxiv.org/abs/1801.04381>
- [11] Minarno, Agus Eko; Wicaksono, Galih Wasis; Azhar, Yufis; Hasanuddin, Muhammad Yusril (2022), "Indonesian Herb Leaf Dataset 3500", Mendeley Data, V1, doi: 10.17632/s82j8dh4rr.1