

Studi Pendahuluan: Analisis Metode *Deep Learning* Untuk Klasifikasi Citra Daun Tanaman Fitomedisin

Mariana Purba^{a1}, Uus Rusmawan^{b2}, Vina Ayumi^{b3}

Fakultas Ilmu Komputer, Universitas Sjakhyakirti^a

Fakultas Teknik dan Informatika, Universitas Dian Nusantara^b

mariana_purba@unisti.ac.id¹, uus.rusmawan@undira.ac.id², vina.ayumi@dosen.undira.ac.id³

Abstrak—Penelitian ini melakukan tinjauan sistematis terhadap penggunaan *deep learning* untuk klasifikasi citra daun tanaman fitomedisin. Tujuan penelitian ini adalah untuk mengidentifikasi berbagai algoritma *deep learning* yang diterapkan dalam identifikasi spesies tanaman fitomedisin dan mengevaluasi kinerja masing-masing algoritma. Metode yang digunakan adalah PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) dengan melakukan analisis studi yang relevan pada database IEEE Xplore, Springer, dan ScienceDirect. Studi yang dipilih kemudian dianalisis berdasarkan algoritma yang digunakan, dataset yang diterapkan, dan hasil akurasi yang diperoleh. Hasil penelitian menunjukkan bahwa algoritma CNN memberikan akurasi yang cukup baik, namun keduanya menghadapi masalah waktu komputasi yang tinggi. Penelitian yang menggunakan ResNet mencapai akurasi tertinggi, yaitu 95,5%, meskipun terdapat masalah dengan latar belakang citra daun. Algoritma Xception, meskipun memberikan akurasi yang lebih rendah, dapat dioptimalkan lebih lanjut dengan meningkatkan ukuran dataset dan teknik yang digunakan. Dalam penelitian ini dibahas penggunaan model MobileNet yang efisien dalam hal komputasi dan dapat mengatasi tantangan-tantangan klasifikasi citra daun tanaman fitomedisin. Model MobileNet (MNET) digunakan untuk klasifikasi daun tanaman fitomedisin karena efisiensinya dalam memproses data besar dengan mengurangi beban komputasi. Perbedaan utama MNET dibandingkan CNN terletak pada penggunaan *depthwise separable convolution*, yang membagi konvolusi menjadi dua bagian yaitu *depthwise convolution* dan *pointwise convolution*. Metode ini dapat mengurangi jumlah parameter, menghasilkan jaringan saraf dalam yang lebih ringan. Dengan arsitektur yang lebih kecil dan latensi rendah, MNET dapat diterapkan untuk klasifikasi citra daun tanaman fitomedisin.

Kata kunci: fitomedisin, CNN, MNET, PRISMA, *deep learning*

Abstract—This study conducted a systematic review of the use of *deep learning* for medicinal plant leaf image classification. The aim of this research was to identify various *deep learning* algorithms applied in the identification of medicinal plant species and evaluate the performance of each algorithm. The method used was PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), which involved analyzing relevant studies from the IEEE Xplore, Springer, and ScienceDirect databases. The selected studies were then analyzed based on the algorithms used, datasets applied, and the accuracy results obtained. The results of the study showed that the CNN algorithm provided reasonably good accuracy, but both faced high computational time issues. A study using ResNet achieved the highest accuracy of 95.5%, although there were issues with the background of the leaf images. The Xception algorithm, although providing lower accuracy, could be further optimized by increasing the dataset size and improving the techniques used. This research discussed the use of the MobileNet model, which is computationally efficient and can address the challenges of medicinal plant leaf image classification. The MobileNet (MNET) model was used for medicinal plant leaf classification due to its efficiency in processing large data while reducing computational load. The main difference between MNET and CNN lies in the use of *depthwise separable convolution*, which divides the convolution into two parts: *depthwise convolution* and *pointwise convolution*. This method reduces the number of parameters, resulting in a lighter *deep neural network* architecture.

Keywords: *phytomedicine*, CNN, MNET, PRISMA, *deep learning*

This is an open access article under the [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) license.



1. Pendahuluan

Pengenalan citra tanaman menjadi salah satu aspek penting dalam bidang pertanian dan farmasi, terutama dalam mengidentifikasi spesies tanaman yang memiliki potensi sebagai obat. Salah satu objek penelitian yang menarik adalah tanaman fitomedisin, yang dikenal karena kemampuannya dalam menghasilkan senyawa bioaktif yang bermanfaat untuk pengobatan. Identifikasi yang tepat terhadap spesies tanaman fitomedisin dapat memberikan kontribusi signifikan dalam pengembangan obat herbal dan terapi alami.


Namun, identifikasi manual tanaman fitomedisin melalui pemeriksaan fisik daun memiliki banyak keterbatasan, termasuk kesalahan manusia dan kebutuhan waktu yang sangat banyak [1]–[4].

Seiring dengan perkembangan teknologi, metode berbasis *deep learning* telah alternatif untuk identifikasi tanaman. Metode *deep learning* menunjukkan hasil yang baik dalam pengenalan citra tanaman berdasarkan citra daun. Penelitian sebelumnya telah mengeksplorasi penggunaan algoritma *deep learning* untuk klasifikasi citra daun tanaman. Metode seperti ResNet, MobileNet, Xception, dan CNN telah diterapkan pada berbagai dataset dengan hasil yang bervariasi. Beberapa penelitian menunjukkan hasil akurasi yang tinggi, namun masih terdapat tantangan terkait dengan faktor-faktor eksternal seperti kualitas citra, pencahayaan, dan latar belakang daun yang dapat mempengaruhi hasil pengenalan. Selain itu, banyak penelitian yang belum memanfaatkan dataset yang cukup besar atau beragam untuk meningkatkan kemampuan generalisasi model [5]–[13].

Metode PRISMA atau dikenal dengan *preferred reporting items for systematic reviews and meta-analyses* digunakan dalam studi ini untuk menganalisis penelitian yang relevan dengan penggunaan algoritma *deep learning* dalam klasifikasi citra daun tanaman fitomedisin. PRISMA membantu untuk menyusun tinjauan literatur terstruktur, untuk memberikan gambaran tentang berbagai algoritma *deep learning* yang digunakan dalam identifikasi citra daun tanaman fitomedisin. Selain itu, penelitian ini juga akan menilai efektivitas dan kekurangan masing-masing metode, serta memberikan rekomendasi untuk penelitian lebih lanjut. Fokus utama dari penelitian ini adalah untuk mengidentifikasi tantangan-tantangan yang masih ada dan peluang untuk meningkatkan akurasi dan efisiensi sistem klasifikasi citra daun tanaman fitomedisin.

2. Metodologi Penelitian

Metode PRISMA diterapkan dalam penelitian ini untuk melakukan tinjauan sistematis terhadap studi-studi terkait klasifikasi citra daun tanaman fitomedisin menggunakan *deep learning*. Proses dimulai dengan mengidentifikasi studi yang relevan melalui pencarian literatur, kemudian dilakukan seleksi dan penyaringan berdasarkan kriteria inklusi dan eksklusi yang jelas. Setelah itu, data dari studi yang memenuhi kriteria dikumpulkan dan disintesis untuk memberikan gambaran umum tentang algoritma, dataset, hasil akurasi, dan rekomendasi untuk penelitian selanjutnya. Tahap penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

Dalam penelitian ini, pencarian studi dilakukan melalui database IEEE Xplore, Springer, dan ScienceDirect untuk mengidentifikasi literatur yang relevan mengenai klasifikasi citra daun tanaman fitomedisin menggunakan *deep learning*. Studi yang dipilih berdasarkan kriteria inklusi dan eksklusi yang sudah ditentukan, yaitu jenis algoritma dan dataset yang digunakan dalam setiap penelitian. Hanya studi yang memenuhi kriteria yang dianalisis, sedangkan yang memiliki penjelasan kurang memadai atau tidak relevan tidak dianalisis lebih lanjut. Proses *filter* ini bertujuan untuk memastikan bahwa hanya penelitian dengan kontribusi yang dianalisis dalam penelitian ini.

Data dari studi yang relevan kemudian dikumpulkan, meliputi algoritma yang digunakan, dataset yang diterapkan, serta hasil akurasi yang diperoleh dalam masing-masing penelitian. Selain itu, kelemahan dan keterbatasan dari setiap studi juga dianalisis untuk memberikan gambaran yang lebih jelas tentang tantangan yang dihadapi. Hasil dari tiap studi disusun dalam bentuk tabel yang mencantumkan peneliti, metode yang diterapkan, tingkat akurasi yang dicapai, dan rekomendasi untuk penelitian lebih lanjut. Sintesis hasil ini diharapkan dapat memberikan pemahaman mengenai tren dan perkembangan penggunaan *deep learning* dalam klasifikasi citra daun tanaman fitomedisin.

3. Hasil dan Pembahasan

Pada tahun 2013, Janani & Gopal menggunakan algoritma ANN dengan dataset 64 citra dan memperoleh akurasi 94,4%, namun tidak mempertimbangkan fitur warna daun. Pada 2019, Azeez & Rajapakse

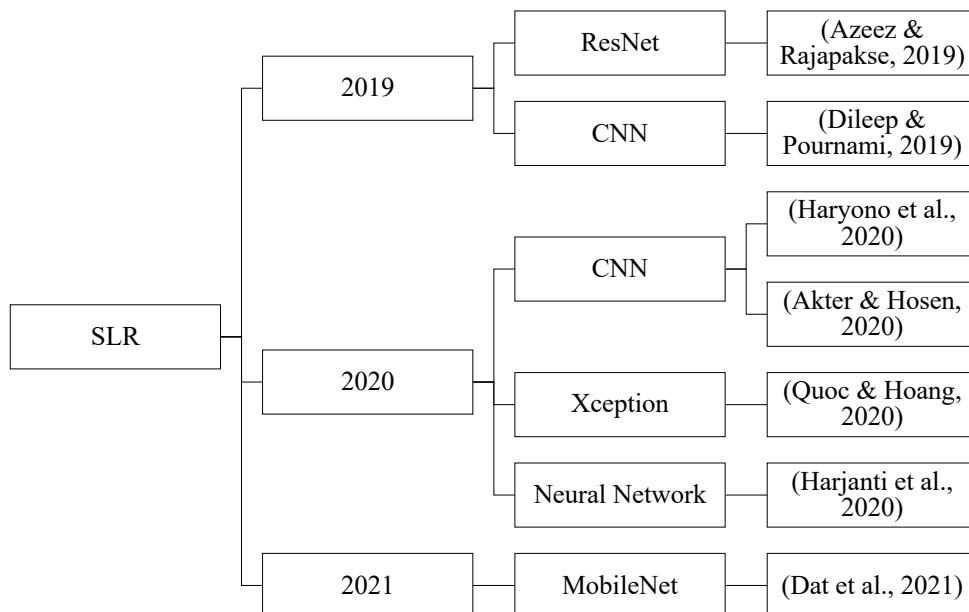
menerapkan ResNet untuk identifikasi citra daun dengan akurasi 95,5%, dan membahas masalah latar belakang pada citra daun. Dileep & Pournami, juga pada 2019, menggunakan CNN dengan dataset 2400 citra dan mencapai akurasi 95,06%, namun memiliki waktu komputasi yang tinggi. Di tahun 2020, Ahila Priyadharshini et al. menggunakan CNN dengan 50 kelas dan akurasi 87,25%, namun algoritma ini membutuhkan waktu komputasi yang tinggi [5]–[13].

Pada tahun 2019, Haryono et al. menggunakan CNN dengan dataset 4050 citra dan akurasi 94,45%, tetapi mereka juga menghadapi masalah waktu komputasi yang tinggi. Penelitian Quoc & Hoang (2020) menggunakan Xception pada 200 citra dengan akurasi 88,26%, namun kinerja model usulan kurang optimal dibandingkan dengan algoritma lain. Dat et al. (2021) menggunakan MobileNet dengan dataset 373 citra dan memperoleh akurasi 97,73%, meskipun penelitian ini dilakukan dalam kondisi pencahayaan yang stabil. Terakhir, Akter & Hosen (2020) menggunakan CNN dengan dataset 34.123 citra, namun hanya mencapai akurasi 71,3%, yang menunjukkan perlunya peningkatan teknik atau penggunaan dataset yang lebih besar [5]–[13]. Hasil SLR dapat dilihat pada Tabel 1.

Tabel 1. Hasil SLR menggunakan PRISMA

Ref	Metode	Hasil
[5]	ResNet	Identifikasi citra daun tanaman fitomedisin dilakukan dengan menggunakan algoritma ResNet. Dataset yang digunakan berjumlah 552 citra tanaman fitomedisin dengan 7 kelas. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 95.5%
[6]	MobileNet	Identifikasi citra daun tanaman fitomedisin dilakukan dengan menggunakan algoritma MobileNet. Dataset yang digunakan Vietnamese Herb Leaf Image (V-Herb) Dataset 373 terdiri dari kelas 29 spesies tanaman fitomedisin yang ada Vietnam. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 97.73%
[7]	CNN	Identifikasi citra daun tanaman fitomedisin dilakukan dengan menggunakan algoritma CNN. Dataset yang digunakan berjumlah 50 kelas tanaman fitomedisin. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 87.25%
[8]	ANN	Identifikasi citra daun tanaman fitomedisin dilakukan dengan menggunakan algoritma Gray-Level Co-Occurrence Matrix (GLCM) dan Artificial Neural Network (ANN). Dataset yang digunakan berjumlah 64 citra daun. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 94,4%.
[9]	CNN	Identifikasi citra daun tanaman fitomedisin dilakukan dengan menggunakan algoritma Convolutional Neural Network (CNN). Dataset yang digunakan berjumlah 2400 citra tanaman fitomedisin. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 95.06
[10]	Xception	Identifikasi citra daun tanaman fitomedisin dilakukan dengan menggunakan algoritma Xception. Dataset yang digunakan berjumlah 200 citra tanaman fitomedisin. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 88.26%
[11]	Neural Network	Identifikasi citra daun tanaman fitomedisin dilakukan dengan menggunakan algoritma <i>Neural Network</i> . Dataset yang digunakan berjumlah 510 citra tanaman fitomedisin. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 84.31%.
[12]	CNN	Identifikasi citra daun tanaman fitomedisin dilakukan dengan menggunakan algoritma Convolutional Neural Network (CNN). Dataset yang digunakan berjumlah 4.050 citra gambar dengan 9 kelas. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 94.45%.
[13]	CNN	Identifikasi citra daun tanaman fitomedisin dilakukan dengan menggunakan Convolutional Neural Network (CNN). Dataset yang digunakan berjumlah 34.123 citra gambar fitomedisin. Hasil dari penelitian ini adalah nilai akurasi yang mencapai 71.3%.

Penelitian selanjutnya perlu mempertimbangkan masalah latar belakang pada citra daun untuk meningkatkan akurasi identifikasi. Perlu adanya eksplorasi dataset yang lebih beragam dengan berbagai kualitas citra untuk memperbaiki hasil klasifikasi, serta mengoptimalkan algoritma agar lebih efisien dalam hal waktu komputasi. Penelitian juga harus fokus pada peningkatan kinerja algoritma yang belum optimal, seperti Xception, dengan memperbesar dataset atau meningkatkan teknik yang digunakan. Selain itu, untuk meningkatkan akurasi pada model CNN, perlu diadopsi teknik yang lebih kuat atau dataset yang lebih besar. Ringkasan mengenai metode deep learning yang digunakan untuk klasifikasi daun tanaman fitomedisin dapat dilihat pada Gambar 2.

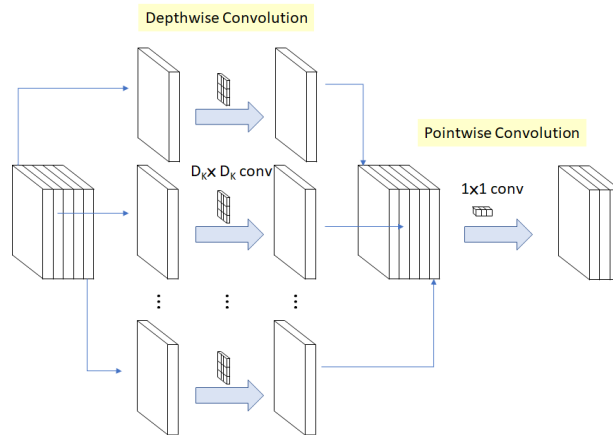


Gambar 2. Infografis hasil SLR

Pada beberapa tahun terakhir, model *MobileNet* atau *MNET* digunakan untuk klasifikasi daun tanaman fitomedisin. Metode ini dapat digunakan untuk mengatasi beban komputasi dalam memproses data dengan jumlah besar. Perbedaan utama antara arsitektur *CNN* dan arsitektur *MNET* adalah implementasi *layer* konvolusi dengan ketebalan *filter* yang menyesuaikan dengan ketebalan dari input citra yang diproses. Arsitektur *MNET* membagi konvolusi menjadi dua bagian yaitu *pointwise convolution* dan *depthwise convolution* [14].

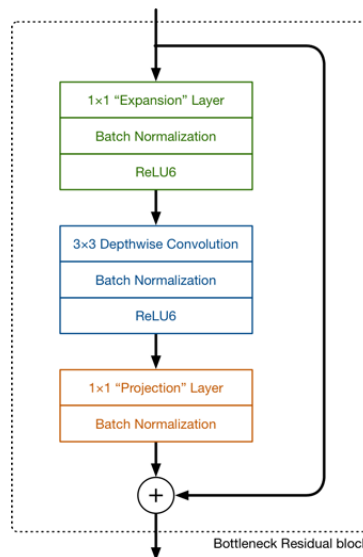
Tren pengembangan arsitektur *CNN* dilakukan berdasarkan jumlah *layer*. Berdasarkan hasil analisa dari *ImageNet large scale visual recognition challenge* atau ILSVRC dari tahun 2010 sampai 2015, semakin banyak jumlah *layer* maka semakin besar kemungkinan untuk mencapai hasil akurasi yang lebih baik [15]. Namun, penerapan banyaknya jumlah *layer* tidak selalu membuat model menjadi lebih efisien dan banyak digunakan. Ini disebabkan karena beberapa bidang seperti robotika, *self-driving car* dan *augmented reality* lebih mengutamakan efisiensi waktu komputasi yang dilatarbelakangi keterbatasan kemampuan komputasi perangkat. Arsitektur *MNET* didesain efisien dengan dua set *hyperparameters* hasil pengembangan dari arsitektur *CNN*. Selain itu, *MNET* dibuat berdasarkan lapisan *depthwise separable convolutions* untuk mengurangi proses komputasi pada *layer* awal. Tujuan utama pengembangan *MNET* adalah untuk membangun model arsitektur yang sangat kecil dan latensi rendah sehingga dapat diimplementasikan sesuai kebutuhan *embedded* dan *mobile applications* [16].

Model *MNET* menggunakan *depthwise separable convolutions*. Metode ini secara signifikan mengurangi jumlah parameter jika dibandingkan dengan jaringan dengan convolution reguler dengan kedalaman yang sama di jaringan. Ini menghasilkan *lightweight deep neural networks* [14], [18]. Sebuah *depthwise separable convolution* terdiri dari dua operasi, yaitu *depthwise convolution* dan *pointwise convolution* [17]. Operasi *depthwise separable convolution* adalah *depthwise convolution* diikuti *pointwise convolution* dapat dilihat pada Gambar 3.



Gambar 3. Depthwise Separable Convolution pada MNET
 Sumber: [17]

Komponen *depthwise convolution* adalah sebuah channel-wise $DK \times DK$ spatial convolution. Misalkan pada gambar di atas terdiri dari lima channel; kemudian, maka ditentukan 5 $DK \times DK$ spatial convolution. Selanjutnya, pointwise convolution adalah convolution 1×1 untuk mengubah dimensi. Pada penelitian ini digunakan MNET versi 2 menggunakan *depthwise separable convolution*, tetapi blok utamanya sekarang terlihat pada Gambar 4.



Gambar 4. Urutan *depthwise separable convolutions* pada MNET
 Sumber: [19]

Berdasarkan gambar diatas, ada tiga *convolutional layer* di blok tersebut. Dua *layer* yang terakhir adalah *depthwise convolution* yang menyaring input, diikuti oleh *pointwise convolution* dengan dimensi 1×1 . Kegunaan dari *layer* dimensi 1×1 ini adalah untuk membuat *channel* lebih kecil atau yang dikenal dengan *projection layer*. *Layer* tersebut dinamakan *projection layer* ini karena *layer* tersebut digunakan memproyeksikan data dengan jumlah dimensi (saluran) yang tinggi ke dalam tensor dengan jumlah dimensi yang jauh lebih rendah [19].

4. Kesimpulan

Penelitian ini berhasil mengidentifikasi berbagai metode deep learning yang digunakan untuk klasifikasi citra daun tanaman fitomedisin, dengan fokus pada algoritma ResNet, MobileNet, CNN, dan Xception. Hasil tinjauan sistematis menunjukkan bahwa algoritma CNN dan MobileNet memberikan akurasi yang baik, meskipun ada tantangan terkait waktu komputasi yang tinggi. Penggunaan dataset dengan kualitas

citra yang bervariasi dapat meningkatkan hasil klasifikasi. Meskipun Xception memiliki akurasi yang lebih rendah, penggunaan dataset yang lebih besar dapat meningkatkan kinerja algoritma. Selain itu, hasil penelitian menunjukkan perlunya pertimbangan lebih lanjut terhadap masalah latar belakang dalam citra daun untuk meningkatkan akurasi identifikasi. Metode MobileNet (MNET) sebagai algoritma yang lebih ringan dibandingkan dengan CNN lainnya, terutama untuk aplikasi mobile dan embedded sehingga dapat direkomendasikan untuk pengembangan lebih lanjut terhadap arsitektur untuk mengurangi beban komputasi pada aplikasi klasifikasi citra daun tanaman fitomedisin.

5. Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada semua pihak yang telah membantu dalam proses penelitian dan penyusunan laporan ini, khususnya kepada UNISTI dan UNDIRA.

6. Daftar Pustaka

- [1] R. A. Sylver-Francis and O. Pelkonen, "Medicinal plants as alternatives for the management of hypertension and diabetes in Nigeria: Analysis of the structured interview of Nigerian patients," *Phytomedicine Plus*, vol. 5, no. 1, p. 100708, 2025.
- [2] A. Lippert and B. Renner, "Herb–drug interaction in inflammatory diseases: Review of phytomedicine and herbal supplements," *Journal of Clinical Medicine*, vol. 11, no. 6, p. 1567, 2022.
- [3] V. Ayumi *et al.*, "Transfer Learning for Medicinal Plant Leaves Recognition: A Comparison with and without a Fine-Tuning Strategy," *International Journal of Advanced Computer Science and Applications*, vol. 13, no. 9, 2022, doi: 10.14569/IJACSA.2022.0130916.
- [4] V. Ayumi, E. Ermatita, A. Abdiansah, H. Noprisson, M. Purba, and M. Utami, "A Study on Medicinal Plant Leaf Recognition Using Artificial Intelligence," in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 40–45. doi: 10.1109/ICIMCIS3775.2021.9699363.
- [5] Y. R. Azeez and C. Rajapakse, "An Application of Transfer Learning Techniques in Identifying Herbal Plants in Sri Lanka," in *2019 International Research Conference on Smart Computing and Systems Engineering (SCSE)*, 2019, pp. 172–178. doi: 10.23919/SCSE.2019.8842681.
- [6] T. Dat, P. Vu, N. Truong, V. Sang, and P. Bao, "Leaf recognition based on joint learning multiloss of multimodel convolutional neural networks: a testing for Vietnamese herb," *Computational Intelligence and Neuroscience*, vol. 2021, 2021, doi: <https://doi.org/10.1155/2021/5032359>.
- [7] R. Ahila Priyadarshini, S. Arivazhagan, and M. Arun, "Ayurvedic Medicinal Plants Identification: A Comparative Study on Feature Extraction Methods," in *International Conference on Computer Vision and Image Processing*, 2020, pp. 268–280. doi: https://doi.org/10.1007/978-981-16-1092-9_23.
- [8] R. Janani and A. Gopal, "Identification of selected medicinal plant leaves using image features and ANN," in *2013 International Conference on Advanced Electronic Systems (ICAES)*, 2013, pp. 238–242. doi: 10.1109/ICAES.2013.6659400.
- [9] M. R. Dileep and P. N. Pournami, "AyurLeaf: A Deep Learning Approach for Classification of Medicinal Plants," in *TENCON 2019 - 2019 IEEE Region 10 Conference (TENCON)*, 2019, pp. 321–325. doi: 10.1109/TENCON.2019.8929394.
- [10] T. N. Quoc and V. T. Hoang, "Medicinal Plant identification in the wild by using CNN," in *2020 International Conference on Information and Communication Technology Convergence (ICTC)*, 2020, pp. 25–29. doi: 10.1109/ICTC49870.2020.9289480.
- [11] T. W. Harjanti, S. Madenda, J. Harlan, and E. T. P. Lussiana, "Study and Research on the Identification of the Leaves of Indonesian Herbal Medicines Using Manhattan Distance and Neural Network Algorithms," in *2020 Fifth International Conference on Informatics and Computing (ICIC)*, 2020, pp. 1–6. doi: 10.1109/ICIC50835.2020.9288564.
- [12] Haryono, K. Anam, and A. Saleh, "A Novel Herbal Leaf Identification and Authentication Using Deep Learning Neural Network," in *2020 International Conference on Computer Engineering, Network, and Intelligent Multimedia (CENIM)*, 2020, pp. 338–342. doi: 10.1109/CENIM51130.2020.9297952.
- [13] R. Akter and M. I. Hosen, "CNN-based Leaf Image Classification for Bangladeshi Medicinal Plant Recognition," in *2020 Emerging Technology in Computing, Communication and Electronics (ETCCE)*, 2020, pp. 1–6. doi: 10.1109/ETCCE51779.2020.9350900.
- [14] A. G. Howard *et al.*, "Mobilenets: Efficient convolutional neural networks for mobile vision

- applications,” *arXiv preprint arXiv:1704.04861*, 2017.
- [15] O. Russakovsky *et al.*, “Imagenet large scale visual recognition challenge,” *International journal of computer vision*, vol. 115, no. 3, pp. 211–252, 2015, doi: <https://doi.org/10.1007/s11263-015-0816-y>.
- [16] B. Khasoggi, E. Ermatita, and S. Sahmin, “Efficient mobilenet architecture as image recognition on mobile and embedded devices,” *Indones. J. Electr. Eng. Comput. Sci.*, vol. 16, pp. 389–394, 2019, doi: <https://doi.org/10.11591/ijeecs.v16.i1.pp389-394>.
- [17] A. Pujara, “Image Classification With MobileNet,” *Medium*, 2020. <https://medium.com/analytics-vidhya/image-classification-with-mobilenet-cc6fbb2cd470> (accessed Aug. 10, 2022).
- [18] W. Sae-Lim, W. Wettayaprasit, and P. Aiyarak, “Convolutional neural networks using MobileNet for skin lesion classification,” in *2019 16th international joint conference on computer science and software engineering (JCSSE)*, 2019, pp. 242–247. doi: <https://doi.org/10.1109/JCSSE.2019.8864155>.
- [19] M. Hollemans, “MobileNet version 2,” *Machine Think*, 2017.
- [20] M. Sandler and A. Howard, “MobileNetV2: The Next Generation of On-Device Computer Vision Networks,” *Google Research*, 2018.

7. Penulis



Mariana Purba adalah dosen di Fakultas Ilmu Komputer, Universitas Sjakhyakirti, dengan keahlian di bidang deep learning dan informatika. Beliau menyelesaikan pendidikan S3 dalam bidang Ilmu Teknik di Universitas Sriwijaya (UNSRI). Penelitian yang dilakukan fokus pada penerapan teknologi deep learning untuk meningkatkan pemahaman dan pengembangan sistem cerdas yang relevan dengan berbagai aplikasi informatika, khususnya dalam topik-topik yang berhubungan dengan kecerdasan buatan dan analisis data.



Uus Rusmawan adalah dosen di Fakultas Teknik dan Informatika, Universitas Dian Nusantara. Beliau memiliki keahlian dalam bidang software development dan pemrograman. Uus Rusmawan memiliki pengalaman dalam mengembangkan perangkat lunak, serta mengajar di berbagai mata kuliah terkait dengan teknologi informasi dan pemrograman. Selain berfokus pada pengajaran, beliau juga aktif melakukan penelitian di bidang software development, dengan menekankan pada inovasi dan penerapan teknologi terkini dalam pengembangan perangkat lunak. Beliau dapat dihubungi melalui email di uus.rusmawan@undira.ac.id.



Vina Ayumi adalah seorang dosen di Fakultas Teknik dan Informatika, Universitas Dian Nusantara. Beliau memiliki spesialisasi dalam bidang deep learning, yang merupakan salah satu subbidang dalam kecerdasan buatan (AI) yang fokus pada pengembangan dan penerapan algoritma untuk memproses data dalam jumlah besar dan kompleks. Vina Ayumi meraih gelar S3 dalam Ilmu Teknik dari Universitas Sriwijaya (UNSRI). Beliau telah berkontribusi dalam penelitian yang mengembangkan teknologi deep learning untuk berbagai aplikasi, termasuk dalam bidang pengolahan citra, pemrosesan bahasa alami, dan aplikasi berbasis AI lainnya.