



Klasifikasi Tumbuhan Obat Berdasarkan Citra Daun Menggunakan Algoritma CNN

Classification of Medicinal Plants Based on Leaf Images Using CNN Algorithm

Nicolas Novelico Sinaga* & Arnes Sembiring

Teknik Informatika, Fakultas Teknik, Universitas Medan Area, Indonesia

*Corresponding Email: Nsinaga260@gmail.com

Abstrak

Penelitian ini bertujuan untuk mengklasifikasikan berbagai jenis tanaman obat berdasarkan citra daun dengan memanfaatkan algoritma *Convolutional Neural Network* (CNN). Model yang digunakan adalah arsitektur *MobileNetV2* karena kemampuannya dalam menyeimbangkan akurasi dan efisiensi komputasi. Dataset citra daun dibagi menjadi data latih dan validasi, kemudian diproses melalui beberapa tahap, seperti *augmentasi*, *fine-tuning*, dan *regularisasi*. Hasil evaluasi menunjukkan bahwa model mencapai akurasi validasi tertinggi sebesar 98,43%, membuktikan bahwa pendekatan ini efektif dalam mengidentifikasi jenis tanaman obat.

Kata Kunci: Klasifikasi Tumbuhan Obat; Citra Daun; CNN; Deep Learning; MobileNetV2.

Abstract

This study aims to classify various types of medicinal plants based on leaf images by utilizing the Convolutional Neural Network (CNN) algorithm. The model used is the MobileNetV2 architecture because of its ability to balance accuracy and computational efficiency. The leaf images dataset is divided into training and validation data, then processed through several stages such as augmentation, fine-tuning, and regularization. The evaluation results show that the model successfully achieved the highest validation accuracy of 98,43%, proving that this approach is effective in identifying types of medicinal plants.

Keywords: Medicinal Plant Classification; Leaf Image; CNN; Deep Learning; MobileNetV2.

PENDAHULUAN

Indonesia merupakan salah satu negara megabiodiversitas yang memiliki kekayaan hayati luar biasa. Diperkirakan terdapat sekitar 50.000 jenis tumbuhan di seluruh wilayah nusantara, dan sekitar 7.500 di antaranya telah diketahui memiliki potensi sebagai bahan obat tradisional [1]. Fenomena ini menunjukkan bahwa masyarakat Indonesia, sejak dahulu kala, telah hidup berdampingan dengan alam dan memanfaatkan tanaman herbal untuk menjaga kesehatan dan mengobati berbagai penyakit. Kecenderungan masyarakat untuk kembali ke pengobatan berbasis alam, terutama di era modern saat ini, semakin memperkuat posisi tanaman obat sebagai bagian dari solusi kesehatan komplementer yang aman, alami, dan terjangkau.

Dalam kerangka kesehatan masyarakat, pemanfaatan tanaman obat menjadi penting karena memberikan alternatif pengobatan bagi kelompok masyarakat yang memiliki keterbatasan akses terhadap fasilitas medis modern. Daun merupakan salah satu bagian tanaman yang paling banyak digunakan dalam pengobatan tradisional karena memiliki kandungan senyawa metabolit sekunder seperti alkaloid, flavonoid, tanin, dan saponin yang berkhasiat bagi tubuh [2]. Pengetahuan lokal tentang penggunaan daun dari tanaman obat diwariskan secara turun-temurun, namun sayangnya belum seluruhnya terdokumentasikan dan terstandarisasi dalam kerangka ilmiah modern. Oleh karena itu, upaya dokumentasi dan identifikasi tanaman obat berbasis ilmu pengetahuan sangat mendesak dilakukan untuk menjaga warisan ini sekaligus mengembangkan potensi farmakologinya secara sistematis.

Salah satu pendekatan ilmiah yang relevan untuk memperkuat dokumentasi dan klasifikasi tanaman obat adalah dengan menggunakan teknologi pencitraan digital. Citra daun, sebagai representasi visual dari morfologi daun, dapat diambil melalui berbagai teknik seperti pemindaian, fotografi digital, atau mikroskopi. Melalui citra ini, karakteristik fisik daun—termasuk bentuk, ukuran, tekstur permukaan, pola vena, dan keberadaan stomata—dapat diidentifikasi dan dianalisis untuk keperluan klasifikasi spesies. Sinaga et al. (2018) menyatakan bahwa citra daun memiliki nilai strategis dalam penelitian farmasi karena dapat membantu mengidentifikasi potensi terapeutik suatu tanaman sebelum dilakukan ekstraksi laboratorium.

Selain untuk tujuan identifikasi spesies, citra daun juga memungkinkan pemetaan kandungan senyawa aktif secara visual. Penelitian Widiastuti et al., (2022) menunjukkan



bahwa tanaman seperti *Andrographis paniculata* (sambiloto) dan *Catharanthus roseus* (tapak dara) memiliki karakteristik morfologi tertentu yang berkorelasi dengan kandungan senyawa aktif seperti andrographolide dan vincristine. Dengan demikian, analisis citra daun dapat digunakan sebagai langkah awal dalam proses screening tanaman obat, sehingga proses ekstraksi dan pemurnian senyawa menjadi lebih terarah dan efisien. Hal ini sangat bermanfaat dalam pengembangan obat berbasis tanaman yang lebih sistematis dan terstandar.

Meskipun teknologi pencitraan telah lama digunakan dalam bidang botani, tantangan utama yang dihadapi adalah keragaman bentuk dan spesies tanaman yang sangat tinggi, yang seringkali menyebabkan kesalahan identifikasi secara manual [5], [6]. Di sinilah kecerdasan buatan, khususnya *Convolutional Neural Network* (CNN), memainkan peran penting. CNN merupakan jenis jaringan saraf tiruan yang dirancang khusus untuk pengolahan dan klasifikasi citra, dengan kemampuan mengekstraksi fitur-fitur penting seperti pola tekstur dan bentuk melalui lapisan-lapisan konvolusi. Triase (2023) menunjukkan bahwa CNN mampu mengklasifikasikan berbagai jenis daun tanaman obat dengan akurasi yang tinggi, sehingga sangat membantu dalam otomatisasi identifikasi tanaman di lapangan.

Selain sebagai alat klasifikasi, CNN juga dapat digunakan untuk mendeteksi kondisi fisiologis tanaman berdasarkan kondisi daunnya. CNN dapat mengenali tanda-tanda stres lingkungan seperti kekeringan, serangan hama, maupun penyakit tanaman. Faqih & Avianto [8] menunjukkan bahwa model CNN yang dilatih dengan dataset gejala penyakit pada daun dapat memberikan sistem peringatan dini bagi petani atau pengelola kebun tanaman obat. Hal ini memiliki dampak signifikan terhadap keberhasilan panen, kualitas bahan baku obat, dan efisiensi dalam proses budidaya tanaman.

Penelitian lain dari Budi Setiyono et al. [9] dengan judul Identifikasi Tanaman Obat Indonesia Melalui Citra Daun Menggunakan Metode Convolutional Neural Network (CNN). Penelitian ini menggunakan metode CNN untuk mengidentifikasi jenis tanaman obat di Indonesia melalui citra daun. Dataset yang digunakan berasal dari Mendeley Data dan data primer dari Kampung Herbal Surabaya. Model CNN yang dikembangkan berhasil mencapai akurasi rata-rata sebesar 98% dalam mengklasifikasikan berbagai jenis tanaman herbal, menunjukkan efektivitas metode ini dalam identifikasi tanaman obat.

Kemudian penelitian berikutnya dari Albakia & Saputra [10] dengan judul Identifikasi Jenis Daun Tanaman Obat Menggunakan Metode Convolutional Neural Network (CNN) Dengan Model VGG16. Penelitian ini menggunakan arsitektur CNN dengan model VGG16 untuk mengidentifikasi 10 jenis daun tanaman obat. Dataset yang digunakan terdiri dari 6.100 citra daun yang dikumpulkan secara mandiri. Model mencapai akurasi pelatihan sebesar 81,61%, akurasi validasi 90,74%, dan akurasi pengujian 92% pada 50 citra daun. Hasil ini menunjukkan potensi penggunaan model VGG16 dalam identifikasi tanaman obat secara otomatis.

Namun demikian, masih terdapat sejumlah tantangan dalam penerapan CNN untuk klasifikasi daun tanaman obat, terutama dalam hal ketersediaan dataset berkualitas tinggi yang mencakup ragam spesies tanaman lokal. Selain itu, belum banyak penelitian yang secara khusus mengintegrasikan analisis citra daun berbasis CNN dengan tujuan eksplorasi senyawa aktif dalam konteks farmasi tradisional Indonesia. Hal ini menjadi celah penelitian (research gap) yang penting untuk dijawab.

Penelitian ini bertujuan untuk mengembangkan pendekatan berbasis *Convolutional Neural Network* dalam mengidentifikasi dan mengklasifikasikan citra daun tanaman obat Indonesia guna mendukung eksplorasi senyawa aktif yang bermanfaat secara medis. Penelitian ini akan membangun model CNN yang mampu mengenali spesies tanaman obat melalui citra daun dan memberikan informasi morfologi yang relevan terhadap kandungan senyawa aktif. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam digitalisasi sumber daya hayati lokal dan mempercepat proses skrining tanaman obat potensial untuk pengembangan obat herbal modern.

METODE PENELITIAN

Deep Learning

Deep Learning juga dikenal sebagai *Deep Neural Network* (DNN), merupakan cabang *Machine Learning* yang mengalami kemajuan signifikan dalam beberapa tahun terakhir [11]. Pendekatan ini menggunakan *Neural Network* untuk mensimulasikan proses pembelajaran otak manusia dan mengekstraksi fitur yang relevan dari data berskala besar, termasuk suara, teks, gambar dan lainnya [12]. Dataset besar sangat penting untuk *Deep Learning* yang efektif karena memiliki kemampuan untuk mengekstraksi fitur dan pola yang signifikan dari data tersebut [13]. Ciri khas dari *Deep Learning* adalah tingkat



kemampuan yang tinggi dengan secara otomatis memahami dan mempelajari pola-pola yang terdapat dalam gambar. *Convolutional Neural Network* (CNN) adalah salah satu arsitektur utama dalam *Deep Learning* yang digunakan untuk pengolahan gambar [14].

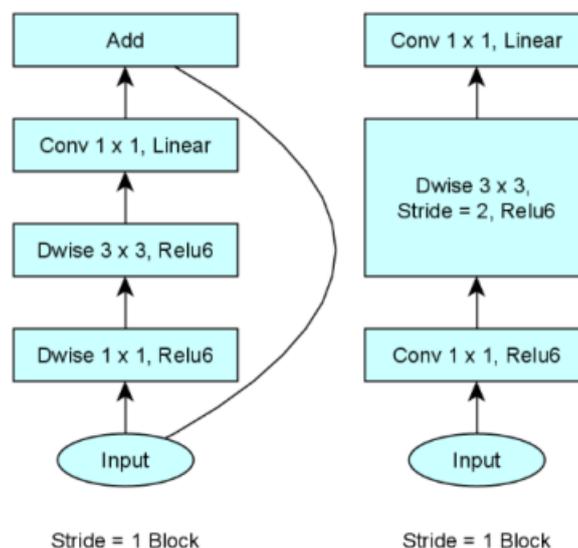
Klasifikasi Daun

Klasifikasi daun merupakan proses mengelompokkan daun berdasarkan karakteristik morfologis seperti bentuk, tepi, dan pola urat, yang digunakan dalam taksonomi tumbuhan untuk mengidentifikasi dan mengelompokkan spesies tanaman. Proses ini sangat penting dalam bidang botani, khususnya dalam penelitian tentang keanekaragaman hayati dan pemanfaatan tanaman obat. Dengan mengklasifikasikan daun, peneliti dapat membedakan spesies yang memiliki kemiripan morfologis dan membantu dalam pelestarian serta pemanfaatan sumber daya alam secara berkelanjutan [15].

Transfer Learning

Transfer Learning merupakan metode yang mengekstraksi bobot dari jaringan yang sudah dilatih sebelumnya (*pretrained model*) dan mentransfernya ke jaringan target lain yang tidak terlatih [16]. *Transfer Learning* membutuhkan model yang sudah dilatih sebelumnya atau dikenal sebagai *pretrained model* untuk mempelajari tugas yang baru [17]. *Pretrained model* yang digunakan pada penelitian ini adalah *MobileNetV2*.

MobileNetV2

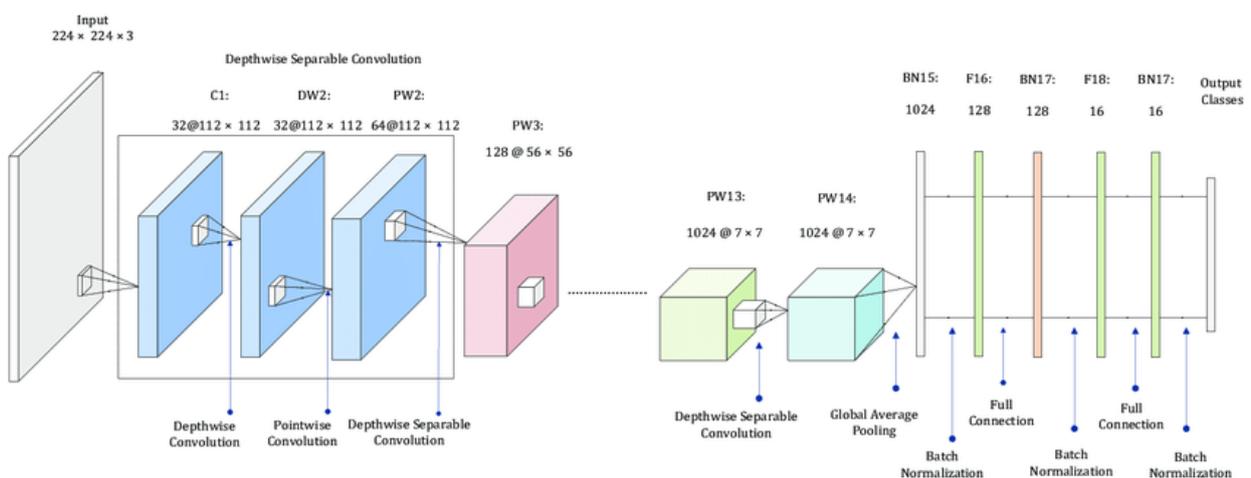


Gambar 1. Arsitektur MobileNetV2

MobileNetV2 yang dirilis pada tahun 2018 masih menggunakan *depth wise* konvolusi seperti pada versi sebelumnya, namun *MobileNetV2* menambahkan dua fitur baru yaitu *linear bottleneck* dan *shortcut connections* antar layer. Struktur dasar dari arsitektur *MobileNetV2* dapat dilihat pada gambar 1 [18]. Arsitektur ini merupakan penyempurnaan dari pendahulunya, *MobileNet*. Perbedaan utama antara *MobileNet* dan arsitektur CNN terletak pada pendekatan dalam penggunaan lapisan konvolusi atau *convolution layer*.

Convolutional Neural Network

Convolutional Neural Network (CNN) adalah salah satu metode yang umum digunakan dalam bidang *Deep Learning* untuk mendeteksi dan mengenali objek dalam citra digital. CNN menerima input berupa gambar dan melalui serangkaian lapisan konvolusi, pooling, dan lapisan tersembunyi, CNN dapat mempelajari representasi fitur yang signifikan dalam gambar. Dengan demikian, CNN dapat secara efektif mengekstraksi informasi penting yang terkandung dalam gambar. CNN sering digunakan dalam analisis citra karena kemampuannya dalam mengenali pola dan fitur dalam data citra. Arsitektur CNN memiliki struktur yang relative sederhana, terdiri dari satu lapisan masukan (*input layer*), beberapa lapisan tersembunyi (*hidden layers*), dan satu lapisan satu lapisan keluaran (*output layer*). CNN menggunakan representasi tiga dimensi yang mencakup lebar (*width*), tinggi (*height*), dan kedalaman (*depth*) [19]. Adapun arsitektur dari CNN dapat ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur CNN

Learning Rate

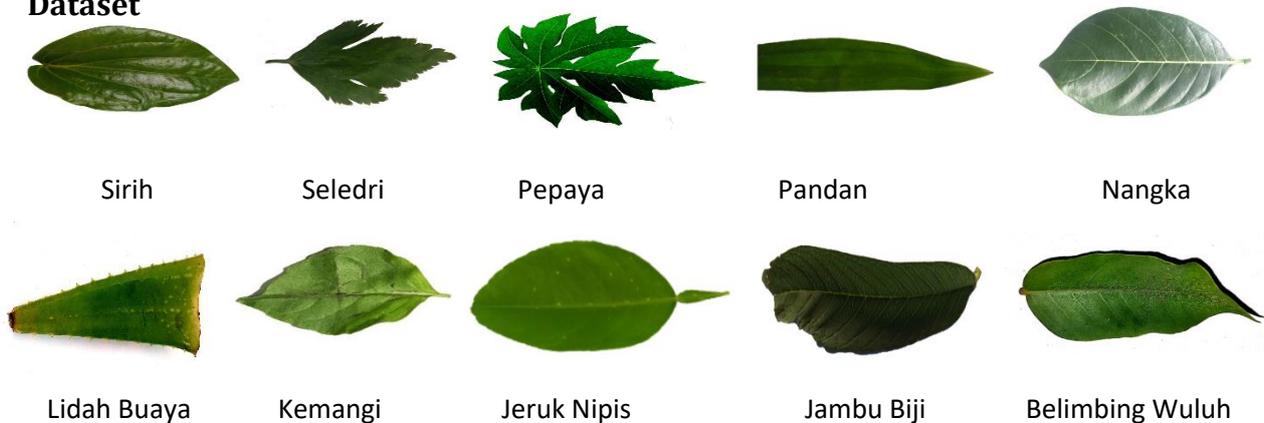
Learning rate adalah *hyperparameter* penting dalam pembelajaran mendalam yang mengatur kecepatan pembaruan bobot model selama proses pelatihan. *Learning rate*

menentukan seberapa besar langkah yang diambil model dalam memperbarui bobot untuk meminimalkan fungsi *loss*. Jika *learning rate* terlalu besar, model dapat menjadi tidak stabil, menyebabkan fluktuasi dalam fungsi *loss*, dan menghambat konvergensi. Sebaliknya, *learning rate* yang terlalu kecil dapat membuat pelatihan sangat lambat, dengan risiko terjebak pada minimum lokal, yang menghalangi pencapaian performa optimal [20].

Batch Size

Batch size adalah parameter penting dalam pelatihan *model Convolutional Neural Network* (CNN) untuk klasifikasi citra, termasuk dalam identifikasi tumbuhan obat berdasarkan citra daun. *Batch size* menentukan jumlah sampel yang diproses dalam satu iterasi sebelum pembaruan bobot dilakukan. Penggunaan *batch size* kecil dan besar, seperti 32 atau 64, menghasilkan pembaruan parameter lebih sering, yang dapat membantu model beradaptasi dengan baik terhadap variasi dalam citra daun, seperti perbedaan bentuk atau warna daun (Beno dkk, 2022).

Dataset

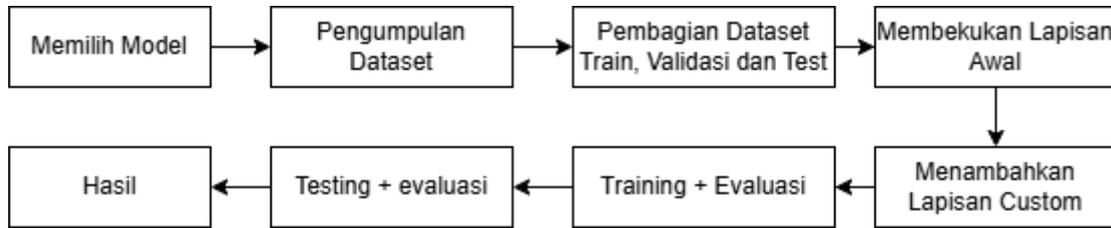


Gambar 3. Contoh citra pada dataset

Dataset yang digunakan dalam penelitian ini berisi citra daun tumbuhan obat, yang dikumpulkan dari sumber *Kaggle* untuk mendukung proses klasifikasi menggunakan *Convolutional Neural Network* (CNN). Setiap gambar dalam dataset telah melalui proses pra-pemrosesan, termasuk *resizing*, *normalisasi*, dan *augmentasi*, guna meningkatkan kualitas data dan memperkuat kemampuan model dalam mengenali pola unik pada setiap jenis daun tumbuhan obat.

Alur Penelitian

Untuk melakukan penelitian agar dapat tercapai tujuan yang telah ditetapkan, maka tahapan penelitian harus dapat tersusun dan terencana dengan baik. Gambar 4 berikut ini, merupakan bagan tahapan penelitian yang dijalankan:



Gambar 4. Alur Penelitian

Sebelum melakukan proses klasifikasi dengan menggunakan arsitektur *MobileNetv2*, gambar tersebut akan masuk ke tahap pra-pemrosesan (*augmentasi*) terlebih dahulu. Ukuran dari dimensi piksel gambar daun tanaman obat yang telah dikumpulkan diubah ukuran dimensi gambar nya sehingga setiap gambar memiliki ukuran yang sama yaitu menjadi 224 x 224 piksel. Selanjutnya merancang model arsitektur untuk pelatihan. Pada penelitian ini, penulis menerapkan metode *transfer learning* untuk melatih model dengan memanfaatkan model yang sudah dilatih sebelumnya.

Parameter Performansi

Parameter performansi merupakan tolak ukur dalam menentukan seberapa bagus kualitas dari sistem yang telah dirancang. Adapun parameter yang diukur dalam penelitian ini adalah *loss*, *akurasi*, *presisi*, *recall*, dan *F1-Score*. Dapat dilihat pada gambar di bawah ini.

$$(1). Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots 3.1$$

$$(2). Precision = \frac{TP}{TP+FP} \dots\dots\dots 3.2$$

$$(3). Recall = \frac{TP}{TP+FN} \dots\dots\dots 3.3$$

$$(4). F1 Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \dots\dots\dots 3.4$$



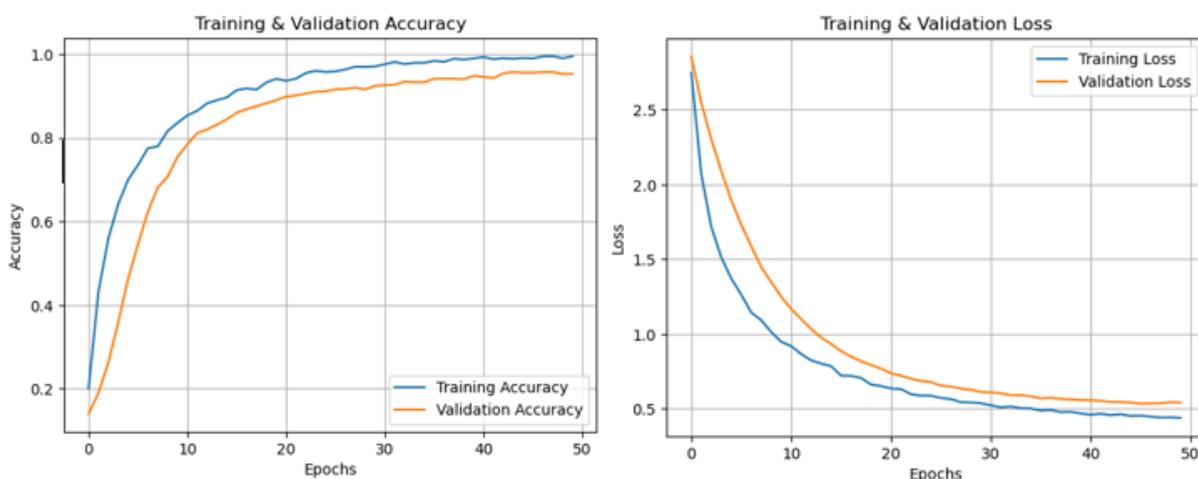
HASIL DAN PEMBAHASAN

Pengujian dengan *batch size* 32 dan 64 serta *learning rate* 0.00001, 0.0001, xsdan 0.001 menunjukkan bahwa kombinasi *batch size* 32 dan *learning rate* 0.00001 memberikan hasil terbaik dengan akurasi tertinggi dan loss terendah. *Learning rate* 0.0001 masih menunjukkan performa yang cukup baik, sedangkan 0.001 menyebabkan fluktuasi yang lebih besar dan risiko *overfitting*. *Batch size* 64 cenderung lebih stabil tetapi sedikit menurunkan akurasi. Dengan demikian, kombinasi *batch size* 32 dan *learning rate* 0.00001 dipilih sebagai konfigurasi optimal untuk model ini.

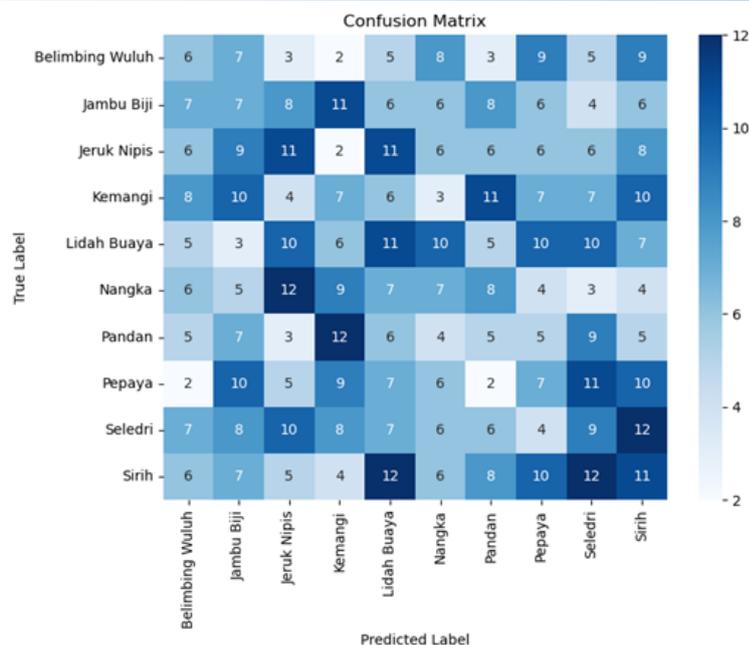
Tabel 1. Hasil Pengujian Batch Size dan Learning Rate

batch	Learning Rate	Train Accuracy	Train Loss	Val Accuracy	Val Loss
32	0.00001	0.9966	0.4361	0.9571	0.5348
	0.0001	0.9997	0.2829	0.9757	0.3786
	0.001	0.9999	0.0090	0.9843	0.0740
64	0.00001	0.9999	0.3761	0.9557	0.5032
	0.0001	0.9999	0.3227	0.9471	0.5190
	0.001	0.9999	0.0106	0.9686	0.1426

Pada hasil yang didapat pada tabel 1, penggunaan *batch size* 32 dan *learning rate* 0.001 menghasilkan performa terbaik dengan akurasi validasi tertinggi sebesar 98.43%, loss validasi 0.0740 dan loss pelatihan juga paling rendah sebesar 0.0090. Hasil ini menunjukkan bahwa model mampu mengenali pola pada dataset dengan sangat baik dan memiliki tingkat kesalahan yang rendah. Learning rate yang kecil membantu model belajar lebih stabil dan menghindari *fluktuasi*, sementara *batch size* 32 memberikan keseimbangan antara kecepatan *konvergensi* dan *generalisasi* model.



Gambar 5. Grafik Accuracy dan Loss



Gambar 6. Confusion Matrix best Batch Size

SIMPULAN

Penelitian ini mengembangkan sistem klasifikasi tanaman obat berdasarkan citra daun menggunakan algoritma *Convolutional Neural Network* (CNN) dengan pendekatan arsitektur *MobileNetV2*. Model ini dirancang untuk mengolah data citra secara efisien dengan memanfaatkan fitur-fitur visual yang relevan tanpa memerlukan sumber daya komputasi besar. Proses pelatihan mencakup teknik augmentasi data, fine-tuning pada beberapa lapisan akhir model, serta penerapan regularisasi guna mengurangi risiko overfitting. Dataset dibagi ke dalam data pelatihan dan validasi agar performa model dapat diuji secara adil dan objektif. Berdasarkan hasil evaluasi, model berhasil mencapai tingkat akurasi validasi tertinggi sebesar **98,43%**, yang menunjukkan bahwa pendekatan ini sangat efektif dalam mengklasifikasi berbagai jenis tanaman obat secara akurat.

DAFTAR PUSTAKA

- [1] B. Setiyono, M. Riv, Q. Q. Aini, and T. H. Soegianto, "Identifikasi Tanaman Obat Indonesia Melalui Citra Daun Menggunakan Metode Convolutional Neural Network (CNN) Identification Of Indonesian Medicine Plants Through Leaf Image Using The Convolutional Neural Network (CNN)," *Method*, vol. 10, no. 2, pp. 385–392, doi: 10.25126/jtiik.2023106809.
- [2] R. Gusnedi, "Analisis Nilai Absorbansi dalam Penentuan Kadar Flavonoid untuk Berbagai Jenis Daun Tanaman Obat," *Pillar Phys.*, vol. 2, pp. 76–83.
- [3] E. Sinaga, M. Rina, and others, "Kadar Flavonoid Total, Daya Antioksidan dan Daya Hepatoprotektif Ekstrak Etanol Rimpang Temu Tis (*Curcuma purpurascens*)," 2018.
- [4] T. C. Widiastuti *et al.*, "Pemanfaatan Tanaman Obat untuk Mengatasi Penyakit Diabetes Melitus di Kota Kebumen," *J. Farm. Klin. dan Sains*, vol. 2, no. 1, pp. 87–96, 2022.

- [5] D. A. Nurlitasari, R. Magdalena, and R. Y. N. Fu'adah, "Analisis Performansi Sistem Klasifikasi Kanker Kulit Menggunakan Convolutional Neural Network," *J. Electr. Syst. Control Eng.*, vol. 5, no. 2, pp. 91–99, 2022, doi: 10.31289/jesce.v5i2.5691.
- [6] S. Rizal, N. Kumalasari Caesar, N. Ibrahim, H. Vidya, S. Saidah, and Y. Nur Fu, "Klasifikasi Daun Teh Seri Gmb Menggunakan Convolutional Neural Network Tea Leaves Gmb Series Clasiffication Using Convolutional Neural Network," *Jesce*, vol. 3, no. 2, p. 2020, 2020, [Online]. Available: <http://ojs.uma.ac.id/index.php/jesce>
- [7] T. Triase, "A Penerapan Deep Learning untuk Identifikasi Citra Tanaman Obat Anti-inflamasi Menggunakan Algoritma CNN: Penerapan Deep Learning untuk Identifikasi Citra Tanaman Obat Anti-inflamasi Menggunakan Algoritma CNN," *Indones. J. Comput. Sci.*, vol. 12, no. 6, 2023.
- [8] A. B. Faqih and D. Avianto, "Identifikasi Penyakit Daun pada Tanaman Solanaceae dan Rosaceae Menggunakan Deep Learning," *J. Teknol. Terpadu*, vol. 10, no. 2, pp. 105–116, 2024.
- [9] B. Setiyono *et al.*, "Identifikasi Tanaman Obat Indonesia Melalui Citra Daun Menggunakan Metode Convolutional Neural Network (CNN)," *J. Teknol. Inf. dan Ilmu Komput.*, 2023, doi: 10.25126/jtiik.2023106809.
- [10] S. A. E. Albakia and R. A. Saputra, "Identifikasi Jenis Daun Tanaman Obat Menggunakan Metode Convolutional Neural Network (CNN) Dengan Model VGG16," *J. Inform. Polinema*, vol. 9, no. 4, pp. 451–460, Aug. 2023, doi: 10.33795/JIP.V9I4.1420.
- [11] W. Zhu, L. Xie, J. Han, and X. Guo, "The application of deep learning in cancer prognosis prediction," *Cancers (Basel)*, vol. 12, no. 3, pp. 1–19, 2020, doi: 10.3390/cancers12030603.
- [12] X. Liu, L. Song, S. Liu, and Y. Zhang, "A review of deep-learning-based medical image segmentation methods," *Sustain.*, vol. 13, no. 3, pp. 1–29, 2021, doi: 10.3390/su13031224.
- [13] M. Kołodziej, A. Majkowski, and A. Rysz, "Implementation of Machine Learning and Deep Learning Techniques for the Detection of Epileptic Seizures Using Intracranial Electroencephalography," *Appl. Sci.*, vol. 13, no. 15, 2023, doi: 10.3390/app13158747.
- [14] J. Naranjo-Torres, M. Mora, R. Hernández-García, R. J. Barrientos, C. Fredes, and A. Valenzuela, "A review of convolutional neural network applied to fruit image processing," *Appl. Sci.*, vol. 10, no. 10, 2020, doi: 10.3390/app10103443.
- [15] S. Adiningsi and R. A. Saputra, "IDENTIFIKASI JENIS DAUN TANAMAN OBAT MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN MODEL VGG16," pp. 451–460, 2020.
- [16] M. A. Wani, F. A. Bhat, Afzal, and Dkk, *Advances in Deep Learning*, vol. 57. 2019. doi: 10.1007/978-981-13-6794-6.
- [17] A. E. Wijaya, W. Swastika, and O. H. Kelana, "IMPLEMENTASI TRANSFER LEARNING PADA CONVOLUTIONAL NEURAL NETWORK UNTUK DIAGNOSIS COVID-19 DAN PNEUMONIA PADA CITRA X-RAY," vol. 2, no. 1, 2021.
- [18] F. A. A. Harahap, A. N. Nafisa, E. N. D. B. Purba, and N. A. Putri, "Implementasi Algoritma Convolutional Neural Network Arsitektur Model Mobilenetv2 Dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary Dan Meningioma," *J. Teknol. Informasi, Komputer, dan Apl. (JTika)*, vol. 5, no. 1, pp. 53–61, 2023, doi: 10.29303/jtika.v5i1.234.
- [19] A. M. Rizki and N. Marina, "Klasifikasi Kerusakan Bangunan Sekolah Menggunakan Metode Convolutional Neural Network Dengan Pre-Trained Model Vgg-16," *J. Ilm. Teknol. dan Rekayasa*, vol. 24, no. 3, pp. 197–206, 2019, doi: 10.35760/tr.2019.v24i3.2396.
- [20] S. Susilawati and M. Muhathir, "Analisis Pengaruh Fungsi Aktivasi, Learning Rate Dan Momentum Dalam Menentukan Mean Square Error (MSE) Pada Jaringan Saraf Restricted Boltzmann Machines (RBM)," *J. Informatics Telecommun. Eng.*, vol. 2, no. 2, p. 77, 2019, doi: 10.31289/jite.v2i2.2162.
- [21] J. Beno, A. . Silen, and M. Yanti, "No 主観的健康感を中心とした在宅高齢者における健康関連指標に関する共分散構造分析Title," *Braz Dent J.*, vol. 33, no. 1, pp. 1–12, 2022.

