

Analisis Komparatif Model Transfer Learning Inception-v3 dan Inception-v4 untuk Klasifikasi Citra Daun Tanaman Herbal

Yosefa Camilia Moniung¹, Muhammad Ezar Al Rivan²

¹Program Studi Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

²Program Studi Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

Email : camiliayosefa@mhs.mdp.ac.id, meedzhar@mdp.ac.id

Article Information

Article history

Received 15 April 2026

Revised 27 May 2026

Accepted 4 June 2026

Available 6 June 2026

Keywords

Classification

Herb Plants

Inception-v3

Inception-v4

Comparison

Corresponding Author:

Yosefa Camillia Moniung,
Universitas Multi Data Palembang,
Email:
camiliayosefa@mhs.mdp.ac.id

Abstract

Herbal plants represent one of Indonesia's rich biodiversity resources that have long been utilized in traditional medicine. However, manual identification remains challenging due to morphological similarities among plant species. Various studies have applied Convolutional Neural Network (CNN) for herbal plant classification, yet comparative analysis between Inception-v3 and Inception-v4 in this domain remains limited. This comparison is necessary as increased architectural complexity in Inception-v4 does not always guarantee better performance on small-scale datasets. This study aims to compare the performance of Inception-v3 and Inception-v4 transfer learning in classifying 10 herbal plant species using 1,000 leaf images. The novelty lies in a direct comparative analysis considering data augmentation and hyperparameter tuning. Pre-processing includes image resizing and augmentation, while hyperparameter tuning applies learning rate variations (0.001; 0.0001; 0.00001) and batch sizes (16, 32, 64). Evaluation was conducted using accuracy, precision, recall, and F1-score. Inception-v3 achieved the best performance with 98.50% accuracy, 98.55% precision, 98.50% recall, and 98.50% F1-score, providing an empirical benchmark for Inception architecture selection in leaf-based herbal plant classification.

Keywords : Classification, Herb Plants, Inception-v3, Inception-v4, Comparison

Abstrak

Tanaman herbal merupakan salah satu kekayaan hayati Indonesia yang telah lama dimanfaatkan dalam pengobatan tradisional. Namun, identifikasi secara manual masih menghadapi kendala berupa kemiripan morfologi antartanaman. Berbagai penelitian telah menerapkan *Convolutional Neural Network* (CNN) untuk klasifikasi tanaman herbal, tetapi analisis komparatif antara Inception-v3 dan Inception-v4 pada domain ini masih terbatas. Perbandingan keduanya diperlukan karena peningkatan kompleksitas arsitektur pada Inception-v4 tidak selalu menjamin performa lebih baik pada dataset berskala kecil dan domain spesifik. Penelitian ini bertujuan membandingkan kinerja transfer learning Inception-v3 dan Inception-v4 dalam klasifikasi 10 jenis tanaman herbal menggunakan 1.000 citra daun. Kebaruan penelitian terletak pada analisis komparatif langsung dengan mempertimbangkan augmentasi data dan hyperparameter tuning. Pre-processing meliputi resize citra dan augmentasi data, sedangkan hyperparameter tuning menggunakan variasi learning rate (0,001; 0,0001; 0,00001) dan batch size (16, 32, 64). Evaluasi dilakukan menggunakan accuracy, precision, recall, dan F1-score. Inception-v3 memberikan performa terbaik dengan accuracy 98,50%, precision 98,55%, recall 98,50%, dan F1-score 98,50%, sehingga memberikan benchmark empiris untuk pemilihan arsitektur Inception pada klasifikasi tanaman herbal berbasis citra daun.

Kata Kunci : Klasifikasi, Tanaman Herbal, Inception-v3, Inception-v4, Perbandingan

Copyright©2026 Yosefa Camilia Moniung, Muhammad Ezar Al Rivan
This is an open access article under the [CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/) license.



1. Pendahuluan

Indonesia merupakan salah satu negara tropis dengan keanekaragaman hayati terbesar di dunia, termasuk sekitar 50.000 spesies tanaman dengan 7.500 spesies yang telah digunakan masyarakat secara turun-temurun sebagai tanaman obat atau tanaman herbal (Adelia dkk., 2025). Pada tanaman herbal, bagian daun merupakan bagian yang paling sering dimanfaatkan untuk pengobatan karena mengandung senyawa bioaktif yang bermanfaat bagi kesehatan manusia (Koniady & Rivan, 2025; Meiriyama dkk., 2022). Namun, masyarakat umumnya kesulitan membedakan jenis tanaman herbal apabila hanya melihat sekilas pada bagian daun, dikarenakan beberapa tanaman memiliki karakteristik daun yang serupa sehingga berpotensi menyebabkan kesalahan identifikasi (Meilani dkk., 2025; Nurdiansyah dkk., 2024). Selain itu, bertambahnya jumlah spesies tumbuhan herbal juga membuat proses klasifikasinya semakin kompleks apabila dilakukan secara manual (Kasim dkk., 2024). Maka dari itu, perkembangan teknologi dapat dimanfaatkan untuk mengatasi permasalahan tersebut.

Salah satu perkembangan teknologi dalam beberapa tahun terakhir adalah teknik *deep learning* yang menunjukkan kemampuan luar biasa dalam proses pengenalan gambar (Azizah dkk., 2024). Metode *deep learning* yang menunjukkan performa paling unggul dalam pengolahan atau pengenalan citra saat ini adalah *Convolutional Neural Network* (CNN) (Christian & Idrus, 2023). CNN bekerja dengan mengekstraksi fitur secara otomatis melalui *convolutional layer*, *pooling layer*, dan aktivasi *Rectified Linear Unit* (ReLU), sehingga mampu mencapai performa yang baik dalam klasifikasi citra tanpa perlu menentukan fitur secara manual sebagaimana pada metode konvensional (Adiningi & Saputra, 2023). Seiring perkembangannya, CNN memiliki berbagai arsitektur yang masing-masing dirancang dengan kedalaman dan struktur berbeda, seperti VGG, ResNet, dan Inception. VGG dan ResNet mampu menghasilkan akurasi yang tinggi, namun kedua arsitektur tersebut membutuhkan sumber daya komputasi yang besar. Sementara itu, Inception menawarkan keseimbangan antara akurasi dan efisiensi melalui blok Inception yang memproses konvolusi berbagai ukuran secara paralel, sehingga mampu menangkap fitur dari berbagai skala spasial tanpa membebani jumlah parameter secara signifikan (Hanggoro, 2025). Kemampuan ekstraksi fitur multiskala ini menjadikan Inception sangat efektif dalam mengenali objek dengan variasi visual yang tinggi, termasuk variasi bentuk daun tanaman herbal, sehingga arsitektur yang digunakan pada penelitian ini adalah Inception.

Arsitektur Inception memiliki beberapa varian, yakni Inception-v1, Inception-v2, Inception-v3, dan Inception-v4. Inception-v1 merupakan arsitektur awal dari varian ini atau disebut GoogleNet, kemudian berkembang menjadi Inception-v2 dengan penerapan *batch normalization*, dan selanjutnya disempurnakan menjadi Inception-v3 dengan menambahkan konsep faktorisasi pada iterasi ketiganya (Andreas & Widhiarso, 2023). Kemudian, Inception-v3 dikembangkan lagi menjadi Inception-v4 dengan desain

yang lebih sederhana dan seragam, ditandai dengan penambahan stem *layer* (Ichwan & Sumantri, 2024). Beberapa penelitian terdahulu telah mengkaji penggunaan Inception-v3 dalam klasifikasi citra dengan hasil yang menjanjikan (Ungkawa & Hakim, 2023) menggunakan Inception-v3 dengan *transfer learning* untuk klasifikasi kematangan buah kopi kuning dan memperoleh akurasi 92%. (Tanesab dkk., 2025) menggunakan Inception-v3 untuk klasifikasi 4.000 citra penyakit daun mangga dan menghasilkan akurasi 99,34%. (Kartarina dkk., 2025) menggunakan Inception-v3 untuk klasifikasi 2.750 citra daun tanaman obat yang terdiri dari 25 kelas dengan akurasi 98,85%. H(Huda dkk., 2023) membandingkan Inception-v3 dan DenseNet-30 untuk klasifikasi 5 varietas daun grapevine, di mana Inception-v3 unggul dengan akurasi 99,5%.

Selain itu, (Tyassari dkk., 2022) menunjukkan bahwa Inception-v3 memiliki performa lebih baik daripada AlexNet dalam deteksi kanker serviks dengan akurasi 89,80%, dan (Wicaksono & Hartato, 2025) membuktikan bahwa Inception-v3 lebih unggul dari VGG16 dalam klasifikasi kanker otak dengan akurasi 91,67% berbanding 82,14%. Di sisi lain, penelitian menggunakan Inception-v4 juga menunjukkan hasil yang baik. (Wahid dkk., 2021) menggunakan Inception-v4 untuk identifikasi penyakit daun tomat dan memperoleh akurasi 90%. (Pratama dkk., 2025) menggunakan Inception-v4 untuk klasifikasi 12 ras kucing dan memperoleh akurasi tertinggi 93,31%. (Dewi & G, 2023) menunjukkan bahwa *hyperparameter tuning* pada Inception-v4 dapat meningkatkan akurasi deteksi penyakit karat kedelai hingga 86%. (Cakmak & Maman, 2025) membandingkan Inception-v4, VGG-13, dan ResNet-50 dalam deteksi kanker paru, Inception-v4 mencapai akurasi tertinggi sebesar 98,80%.

Penelitian-penelitian terdahulu menunjukkan bahwa Inception-v3 dan Inception-v4 memiliki performa yang baik dalam klasifikasi citra di berbagai domain. Namun, penelitian yang secara langsung membandingkan kedua arsitektur tersebut dalam klasifikasi tanaman herbal berdasarkan citra daun masih sangat terbatas. Oleh karena itu, penelitian ini bertujuan mengimplementasikan model klasifikasi tanaman herbal berbasis deep learning dengan membangun, membandingkan, dan mengevaluasi performa arsitektur Inception-v3 dan Inception-v4 dalam mengklasifikasikan 10 jenis tanaman herbal, yaitu daun jambu biji, daun kari, daun kemangi, daun kunyit, daun mint, daun pepaya, daun sirih, daun sirsak, lidah buaya, dan teh hijau. *Dataset* yang digunakan adalah *dataset* Tumbuhan Herbal dari Kaggle, dengan *preprocessing* berupa *resize* citra ke ukuran 299×299 piksel serta augmentasi data berupa rotasi, *flip horizontal*, *flip vertikal*, dan *color jitter*. Kedua arsitektur dibangun menggunakan metode *transfer learning* berbasis bobot *pretrained ImageNet*, dengan *hyperparameter tuning* pada *learning rate* 0,001; 0,0001; dan 0,00001, serta *batch size* 16, 32, dan 64. Evaluasi performa model dilakukan menggunakan *confusion matrix* dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Penelitian ini dibatasi hanya pada klasifikasi berdasarkan citra daun pada dataset yang digunakan. Penelitian ini diharapkan dapat berkontribusi sebagai referensi perbandingan

arsitektur Inception-v3 dan Inception-v4 dalam klasifikasi tanaman herbal berbasis citra daun menggunakan pendekatan *deep learning*, sekaligus memberikan pemahaman tentang pengaruh augmentasi data dan *hyperparameter tuning* terhadap performa model klasifikasi citra.

2. Kajian Terdahulu

Penelitian-penelitian yang telah dilakukan menunjukkan bahwa berbagai pendekatan telah digunakan dalam klasifikasi citra daun tanaman herbal. (Arnardito & Sasongko, 2024) membandingkan EfficientNetB7 dan MobileNetV2 untuk klasifikasi 10 jenis tanaman herbal Indonesia menggunakan dataset Tanaman Herbal dari Kaggle, dan keduanya berhasil mencapai akurasi 98% dengan EfficientNetB7 yang lebih unggul pada metrik presisi, *recall*, dan *F1-score*. Sementara itu, (Koniady & Rivan, 2025) mengklasifikasikan jenis daun tanaman herbal menggunakan arsitektur AlexNet dengan dataset yang sama, dan hasil terbaik diperoleh pada skenario *batch size* 32 dan *epoch* 25 dengan akurasi pengujian hanya sebesar 73,50%. Kedua penelitian tersebut menunjukkan bahwa arsitektur CNN yang lebih modern menghasilkan performa yang lebih optimal dibanding arsitektur konvensional seperti AlexNet, namun keduanya tidak mengeksplorasi arsitektur Inception yang dikenal efisien dalam ekstraksi fitur multiskala.

Beberapa penelitian telah membuktikan efektivitas Inception-v3 dalam berbagai domain klasifikasi citra. (Kartarina dkk., 2025) menggunakan Inception-v3 dengan *transfer learning* untuk mengklasifikasikan 2.750 citra daun tanaman obat ke dalam 25 kelas dan menghasilkan akurasi 98,85%. Hasil serupa juga ditunjukkan oleh (Tanesab dkk., 2025) yang menerapkan Inception-v3 dengan *transfer learning* dan *optimizer* Adam pada 4.000 citra penyakit daun mangga, menghasilkan akurasi 99,34%. Kedua penelitian ini menunjukkan bahwa kombinasi Inception-v3 dengan *transfer learning* dan *optimizer* Adam dapat menghasilkan akurasi yang sangat baik dalam klasifikasi tanaman herbal. Di luar domain tanaman, (Wicaksono & Hartato, 2025) membandingkan Inception-v3 dan VGG16 dalam klasifikasi deteksi kanker otak, di mana Inception-v3 menghasilkan akurasi 91,67% dan terbukti lebih unggul dari VGG16 yang hanya mencapai 82,14%. (Trihardianingsih dkk., 2023) juga membandingkan Inception-v3 dan ResNet-50 pada klasifikasi penyakit daun teh, dengan Inception-v3 memperoleh akurasi 97,62% dibanding ResNet-50 sebesar 97,44%. Meskipun seluruh penelitian tersebut menunjukkan performa Inception-v3 yang baik, tidak ada yang membandingkannya secara langsung dengan Inception-v4 sebagai varian yang lebih baru dari arsitektur yang sama.

Di sisi lain, penelitian yang menggunakan Inception-v4 juga telah dilakukan di berbagai bidang. (Wahid dkk., 2021) menggunakan Inception-v4 untuk mengidentifikasi dan mengklasifikasikan penyakit daun tomat dengan 2.000 data dan menghasilkan akurasi 90%, membuktikan bahwa Inception-v4 mampu bekerja dengan baik pada

domain klasifikasi daun. (Pratama dkk., 2025) menggunakan Inception-v4 untuk klasifikasi 12 ras kucing dari Oxford IIIT Pet Dataset dengan 25 *epoch* dan memperoleh akurasi 90%. (Dewi & G, 2023) melakukan *hyperparameter tuning* pada Inception-v4 untuk deteksi penyakit karat kedelai dengan berbagai variasi *optimizer*, *learning rate*, *batch size*, dan *epoch*, dan hasilnya menunjukkan bahwa *hyperparameter* yang tepat dapat meningkatkan akurasi hingga 86%. Sementara itu, Cakmak dan Maman (Cakmak & Maman, 2025) membuktikan keunggulan Inception-v4 atas VGG-13 dan ResNet-50 dalam mendeteksi kanker paru dari gambar *CT Scan* dengan akurasi tertinggi 98,80%. Namun, dari semua penelitian tersebut, belum ada penelitian yang menggunakan Inception-v4 pada domain tanaman herbal.

Adapun penelitian yang secara langsung membandingkan Inception-v3 dan Inception-v4 adalah penelitian yang dilakukan oleh Nandini dan Puviarasi (Nandini & Puviarasi, 2021) untuk mendeteksi kanker kulit dari gambar dermis, di mana Inception-v4 terbukti lebih unggul dengan akurasi 92,18% dibandingkan Inception-v3 yang menghasilkan akurasi 90,18%. Meskipun demikian, penelitian tersebut dilakukan pada domain citra medis yang memiliki karakteristik *visual* sangat berbeda dengan citra daun tanaman herbal, sehingga belum dapat disimpulkan Inception-v4 juga akan lebih unggul dibandingkan Inception-v3 pada domain klasifikasi tanaman herbal.

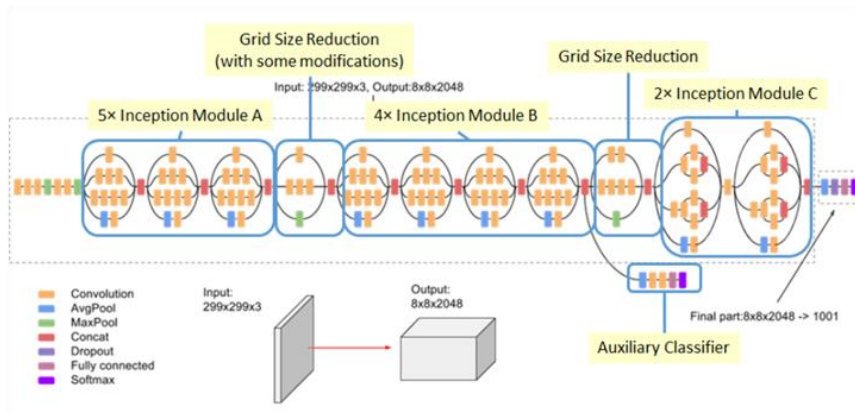
Berdasarkan kajian penelitian terdahulu di atas, dapat diidentifikasi bahwa penelitian-penelitian sebelumnya yang berkaitan dengan klasifikasi tanaman herbal seperti (Arnandito & Sasongko, 2024) dan (Koniady & Rivan, 2025) belum menggunakan arsitektur Inception, sementara penelitian yang menggunakan Inception-v3 maupun Inception-v4 belum diterapkan pada domain tanaman herbal secara komparatif. Maka dari itu, penelitian ini akan membandingkan secara langsung Inception-v3 dan Inception-v4 dalam klasifikasi tanaman herbal menggunakan dataset Tanaman Herbal dari Kaggle, disertai *hyperparameter tuning* dan analisis pengaruh augmentasi data, sehingga diharapkan dapat memberikan kontribusi baru sekaligus menjadi referensi yang lebih komprehensif bagi penelitian selanjutnya di bidang klasifikasi tanaman herbal berbasis *deep learning*.

Tanaman Herbal

Tanaman herbal merupakan tanaman yang dapat dimanfaatkan sebagai pengobatan tradisional maupun alternatif baik daun, batang, maupun akarnya (Azzahra, 2025). Penggunaan tanaman herbal sudah dilakukan sejak dulu oleh masyarakat bahkan dunia karena kemampuannya mengatasi penyakit kronis secara efektif dengan efek toksik yang lebih rendah dibandingkan obat konvensional (Munaeni dkk., 2022). Namun, perkembangan jaman ini membuat banyak masyarakat sulit membedakan tanaman herbal dari daunnya karena pola bentuk yang bervariasi (Ahmad dkk., 2023).

Inception-v3

Inception-v3 merupakan arsitektur buatan Google yang memiliki *parallel convolution* dan memiliki keunikan, yaitu menggabungkan teknik normalisasi dan regulasi untuk meningkatkan kinerja dan mencegah *overfitting* (Sujiwanto dkk., 2023). Inception-v3 memiliki 42 *layers* sehingga dinilai lebih efisien dalam segi kedalaman arsitektur dan *error rate* yang kecil (Rozi dkk., 2023). Gambar 1 menunjukkan arsitektur Inception-v3.

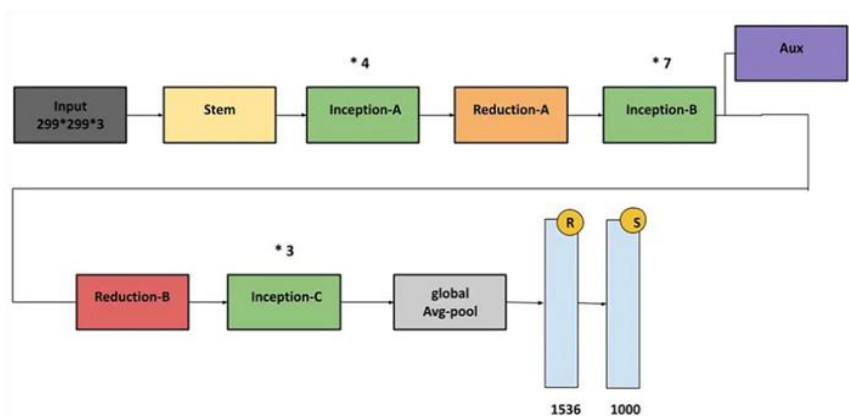


Gambar 1. Arsitektur Inception-v3 (Pratiwi & Pardede, 2022)

Inception-V3 memiliki beberapa keunggulan arsitektur dibandingkan model sebelumnya. Faktorisasi konvolusi diterapkan untuk menjaga efisiensi jaringan, termasuk penggunaan dua filter 3×3 sebagai pengganti konvolusi 5×5 yang lebih hemat parameter (18 vs 25), serta konvolusi asimetris 1×3 dan 3×1 sebagai alternatif konvolusi 3×3 yang lebih efisien secara komputasi. Selain itu, auxiliary classifier disisipkan selama pelatihan sebagai regularizer untuk membantu menghitung loss tambahan, serta reduksi ukuran grid melalui teknik pooling khusus guna meminimalkan inefisiensi komputasi (Rastogi dkk., 2023).

Inception-v4

Arsitektur ini merupakan pengembangan dari Inception-v3. Arsitektur ini menerima *input* sama dengan Inception-v3, yaitu $299 \times 299 \times 3$. Inception-v4 terdiri dari tiga bagian utama, yaitu stem (bagian awal), blok Inception dan *Reduction*, dan bagian akhir (*classification head*). Gambar arsitektur ini dapat dilihat pada Gambar 2 (Dewi & G, 2023).



Gambar 2. Arsitektur Inception-v4

Proses yang dilakukan oleh arsitektur ini dimulai dari input citra berukuran $299 \times 299 \times 3$. Blok pertama (stem) memproses citra *input* melalui beberapa tahap konvolusi secara berurutan dan menghasilkan *feature map* akhir berukuran $35 \times 35 \times 384$ (Nazir dkk., 2022). Kemudian, kemudian diteruskan ke empat modul Inception-A untuk menangkap *feature map multiscale*. Lalu, lapisan Reduction-A memperkecil dimensi menjadi $17 \times 17 \times 1024$, diikuti tujuh modul Inception-B untuk ekstraksi fitur yang lebih kompleks. Selanjutnya, Reduction-B mengurangi resolusi menjadi $8 \times 8 \times 1536$, dan tiga modul Inception-C menangkap pola abstrak tingkat tinggi (Pratama dkk., 2025). Tahap akhir meliputi *global average pooling* yang menghasilkan vektor berdimensi 1536, lapisan *dropout* untuk mencegah *overfitting*, dan lapisan *softmax* yang mengklasifikasikan citra ke dalam 1000 kelas.

Transfer Learning

Teknik *deep learning* yang dilakukan dengan memanfaatkan model yang telah dilatih pada suatu permasalahan untuk menyelesaikan permasalahan lain (Alya dkk., 2023). Oleh karena itu, dengan menggunakan *transfer learning*, proses pelatihan lebih mendalam meskipun dengan *sample* yang terbatas sehingga menghasilkan akurasi yang tinggi.

Confusion Matrix

Confusion matrix digunakan untuk mengevaluasi kinerja model dengan menunjukkan jumlah gambar yang berhasil diklasifikasikan dengan benar atau salah di setiap kelas, yang dibagi menjadi empat komponen utama: *true positive* (TP), *false positive* (FP), *true negative* (TN), dan *false negative* (FN) (Widyatama dkk., 2025). Dari keempat komponen tersebut dapat dihitung *accuracy* (rasio prediksi benar dari keseluruhan data sesuai dengan label atau kelasnya), *precision* (rasio prediksi benar dari keseluruhan hasil yang diprediksi positif), *recall* (rasio prediksi benar dari keseluruhan data yang memang

benar), dan *f1-score* (rasio perbandingan antara nilai rata-rata *precision* dan *recall*) (Nurdin dkk., 2024).

3. Metodologi Penelitian

Dalam pelaksanaan penelitian ini, diterapkan perancangan metode terlebih dahulu untuk meminimalisir kesalahan dalam proses penelitian. Tahapan metodologi penelitian dapat dilihat pada Gambar 3.



Gambar 3. Tahapan Metodologi Penelitian

Studi Literatur

Tahapan ini dimulai dengan mempelajari literatur berupa jurnal-jurnal terkait topik penelitian ini, yaitu klasifikasi tanaman herbal berbasis citra daun menggunakan Inception-v3 dan Inception-v4.

Pengumpulan Dataset

Pada penelitian ini, dataset yang digunakan adalah Dataset Tumbuhan Herbal dari kaggle (<https://www.kaggle.com/anewiamutiaraatha/dataset-tanaman-herbal>) yang berisi 10 jenis tumbuhan herbal dengan masing-masing jenis terdiri dari 100 citra sehingga total ada 1.000 citra *dataset*. Tumbuhan-tumbuhan tersebut adalah daun jambu biji, daun kari, daun kemangi, daun kunyit, daun mint, daun pepaya, daun sirih, daun sirsak, lidah buaya, dan teh hijau. Dataset penelitian ini telah terbagi menjadi data latih dan data uji dengan perbandingan 80:20 sehingga tidak perlu dibagi secara manual lagi.

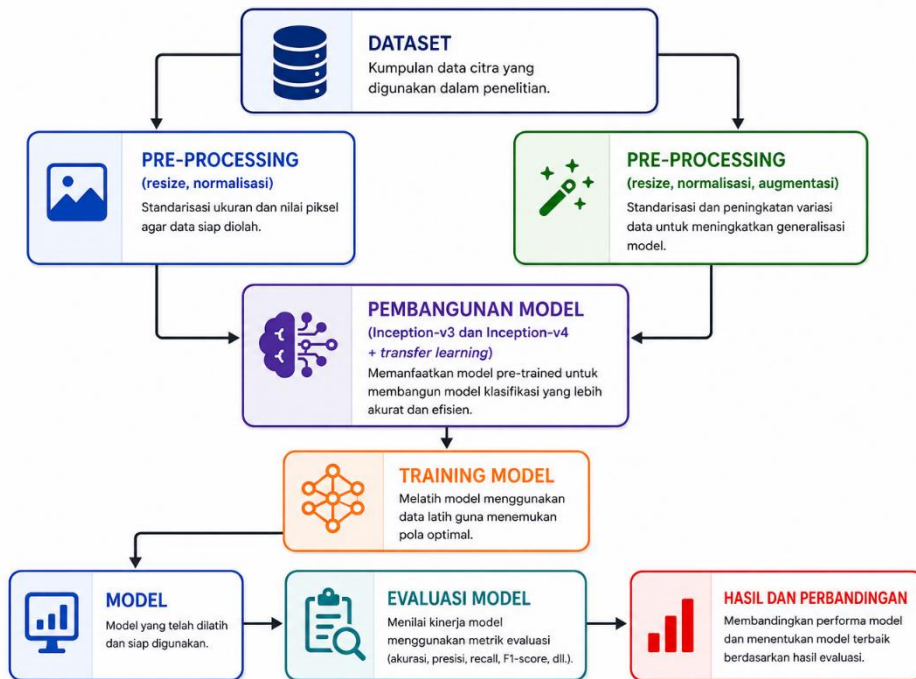
Perancangan

Pada tahapan ini dilakukan perancangan sistem yang dibutuhkan. Perancangan ini melalui beberapa tahapan utama, yaitu pengumpulan dataset, *pre-processing* data, pembangunan model, pelatihan, dan evaluasi. Dataset yang digunakan sebanyak 1.000 citra telah dibagi menjadi 800 data latih dan 200 data uji, dengan masing-masing kelas terdiri dari 80 citra latih dan 20 citra uji. Jumlah dataset yang terbatas ini (hanya 1.000 citra untuk 10 kelas) menyebabkan adanya resiko *overfitting*, maka untuk mengatasinya akan dilakukan augmentasi dan *transfer learning*. Dataset akan melalui tahap *preprocessing* terlebih dahulu yang dilakukan dengan *resize input* menjadi ukuran 299×299 piksel, lalu dinormalisasi.

Untuk menganalisis pengaruh augmentasi terhadap performa model, penelitian ini membandingkan dua kondisi pelatihan, yaitu tanpa augmentasi dan dengan augmentasi. Kondisi tanpa augmentasi dijadikan sebagai *baseline*, di mana data latih hanya melalui proses *resize* dan normalisasi. Pada kondisi dengan augmentasi, diterapkan teknik *random horizontal flip*, *random vertical flip*, rotasi hingga 20 derajat, serta *color jitter* dengan perubahan kecerahan, kontras, dan saturasi sebesar 20% pada data latih. Data uji pada kedua kondisi hanya melalui proses *resize* dan normalisasi tanpa augmentasi. Kedua model dibangun menggunakan pendekatan *transfer learning* dengan bobot *pretrained ImageNet* sebagai inisialisasi awal, dan seluruh layer dilatih ulang (*full fine-tuning*) tanpa pembekuan layer manapun. Untuk menentukan kombinasi *hyperparameter* yang optimal, dilakukan eksperimen dengan 18 skenario untuk 2 arsitektur dengan variasi *learning rate* sebesar 0,001, 0,0001, dan 0,00001, serta variasi *batch size* sebesar 16, 32, dan 64.

Evaluasi performa model dilakukan pada data uji menggunakan *confusion matrix* yang meliputi metrik akurasi, presisi, *recall*, dan *F1-score*. Hasil dari seluruh 18 skenario direkap dalam bentuk tabel untuk membandingkan performa tiap kombinasi *hyperparameter* pada kedua arsitektur, kemudian skenario terbaik dipilih berdasarkan nilai akurasi tertinggi. Hasil perbandingan antar model akan dianalisis secara mendalam dengan mempertimbangkan seluruh metrik evaluasi, yaitu akurasi, presisi, *recall*, dan *F1-score*. Perbandingan dilakukan pada tiga hal, yaitu perbandingan antara Inception-v3 dan

Inception-v4 untuk mengetahui arsitektur yang paling optimal dalam klasifikasi tanaman herbal, perbandingan antara kondisi dengan augmentasi dan tanpa augmentasi untuk membuktikan kontribusi augmentasi terhadap peningkatan performa, serta perbandingan hasil terbaik penelitian ini dengan penelitian terdahulu yang menggunakan dataset yang sama, yaitu AlexNet (Koniady & Rivan, 2025) dan EfficientNetB7 (Arnardito & Sasongko, 2024). Analisis juga akan mencakup pembahasan mengenai kombinasi *hyperparameter* (*learning rate* dan *batch size*) yang paling berpengaruh terhadap performa kedua model.



Gambar 4. Skema Perancangan Sistem

Implementasi

Implementasi akan dilakukan menggunakan bahasa pemrograman Python dengan *framework* PyTorch pada platform Google Colaboratory dengan GPU Tesla T4. *Library* utama yang digunakan meliputi *torchvision* untuk Inception-v3, *timm* (PyTorch Image Models) untuk Inception-v4, *torch* untuk proses pelatihan, *sklearn* untuk evaluasi metrik, serta *matplotlib* dan *seaborn* untuk visualisasi hasil.

Seluruh citra di-*resize* ke 299×299 piksel dan dinormalisasi. Augmentasi diterapkan hanya pada data latih, meliputi *random horizontal flip*, *random vertical flip*, rotasi hingga 20° , dan *color jitter*. Proses load model dilakukan dengan memanfaatkan bobot *pretrained ImageNet* sebagai inisialisasi awal. Inception-v3 di-*load* melalui *torchvision.models.inception_v3(pretrained=True)*, sedangkan Inception-v4 di-*load* melalui *timm.create_model('inception_v4', pretrained=True)* karena *torchvision* tidak menyediakan

arsitektur ini secara resmi. Modifikasi *classifier* dilakukan setelah *load* model. Pada Inception-v3, *layer fully connected akhir* beserta *layer AuxLogits* diganti dengan *layer linear* baru berisi 10 kelas. Pada Inception-v4, penggantian *classifier* dilakukan melalui parameter *num_classes=10* pada fungsi *timm.create_model*. Seluruh *layer* dilatih ulang (*full fine-tuning*) tanpa pembekuan *layer* manapun. Pelatihan dilakukan menggunakan *optimizer* Adam selama 25 *epoch* dengan 18 skenario variasi *hyperparameter* (kombinasi *learning rate* 0,001, 0,0001, 0,00001 dan *batch size* 16, 32, 64). Model dengan akurasi tertinggi dari setiap skenario disimpan dalam format *.pth*.

Pengujian

Pada tahapan ini, sistem yang telah dibuat sebelumnya akan dilakukan uji coba. Setelah pengujian berhasil, hasil pengujian akan dihitung menggunakan *confusion matrix* dengan menghitung nilai *accuracy*, *precision*, *recall*, dan *F1-score* yang dapat dilihat pada Persamaan (1), (2), (3), dan (4).

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

$$\text{F1 - score} = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \times 100\% \quad (4)$$

Keterangan:

TP: Jumlah data yang kelas aktualnya positif yang diprediksi positif oleh sistem

TN: Jumlah data yang kelas aktualnya negatif yang diprediksi negatif oleh sistem

FN: Jumlah data yang kelas aktualnya positif yang diprediksi negatif oleh sistem

FP: Jumlah data yang kelas aktualnya negatif yang diprediksi positif oleh sistem

Nilai *precision*, *recall*, dan *F1-score* dihitung menggunakan *macro average* dan *weighted average* untuk memberikan gambaran performa model secara menyeluruh pada setiap kelas tanaman herbal (Koniady & Rivan, 2025).

4. Hasil dan Pembahasan

4.1. Hasil Eksperimen *Hyperparameter*

Tahapan ini dilakukan eksperimen untuk menentukan kombinasi *hyperparameter* yang paling optimal dari arsitektur Inception-v3 dan Inception-v4. Setiap arsitektur diuji dengan 9 kombinasi *hyperparameter* yang merupakan kombinasi dari 3 variasi *learning rate* (0,001; 0,0001; dan 0,00001) dan 3 variasi *batch size* (16, 32, dan 64) dengan jumlah *epoch*

tetap sebanyak 25 pada kondisi data latih tanpa augmentasi dan dengan augmentasi. Hasil seluruh eksperimen dapat dilihat pada Tabel 1 dan Tabel 2.

Tabel 1. Hasil Hyperparameter Tuning Tanpa Augmentasi

TANPA AUGMENTASI						
Model	Skenario	Learning Rate	Batch Size	Epoch	Train Accuracy	Test Accuracy
Inception-v3	1	0.001	16	25	99.25%	90.50%
Inception-v3	2	0.001	32	25	99.62%	91.00%
Inception-v3	3	0.001	64	25	100.00%	67.50%
Inception-v3	4	0.0001	16	25	100.00%	94.50%
Inception-v3	5	0.0001	32	25	100.00%	97.00%
Inception-v3	6	0.0001	64	25	100.00%	96.00%
Inception-v3	7	0,00001	16	25	100.00%	96.00%
Inception-v3	8	0,00001	32	25	100.00%	96.50%
Inception-v3	9	0,00001	64	25	100.00%	96.50%
Inception-v4	1	0.001	16	25	97.75%	89.50%
Inception-v4	2	0.001	32	25	98.50%	81.00%
Inception-v4	3	0.001	64	25	99.62%	87.50%
Inception-v4	4	0.0001	16	25	100.00%	94.00%
Inception-v4	5	0.0001	32	25	100.00%	98.50%
Inception-v4	6	0.0001	64	25	100.00%	93.00%
Inception-v4	7	0,00001	16	25	100.00%	95.00%
Inception-v4	8	0,00001	32	25	100.00%	95.00%
Inception-v4	9	0,00001	64	25	100.00%	93.50%

Tabel 2. Hasil Hyperparameter Tuning Dengan Augmentasi

DENGAN AUGMENTASI						
Model	Skenario	Learning Rate	Batch Size	Epoch	Train Accuracy	Test Accuracy
Inception-v3	1	0.001	16	25	98.62%	89.00%
Inception-v3	2	0.001	32	25	99.13%	92.50%
Inception-v3	3	0.001	64	25	99.25%	91.00%
Inception-v3	4	0.0001	16	25	100.00%	93.50%
Inception-v3	5	0.0001	32	25	100.00%	97.50%
Inception-v3	6	0.0001	64	25	100.00%	98.50%
Inception-v3	7	0,00001	16	25	99.88%	97.00%
Inception-v3	8	0,00001	32	25	99.75%	94.50%
Inception-v3	9	0,00001	64	25	100.00%	92.00%
Inception-v4	1	0.001	16	25	97.12%	82.50%
Inception-v4	2	0.001	32	25	98.25%	89.00%
Inception-v4	3	0.001	64	25	99.00%	67.50%

Inception-v4	4	0.0001	16	25	99.75%	95.50%
Inception-v4	5	0.0001	32	25	100.00%	82.50%
Inception-v4	6	0.0001	64	25	100.00%	98.50%
Inception-v4	7	0,00001	16	25	99.50%	43.50%
Inception-v4	8	0,00001	32	25	99.62%	46.00%
Inception-v4	9	0,00001	64	25	99.88%	51.50%

Dalam penelitian ini, kondisi tanpa augmentasi dijadikan sebagai *baseline* untuk mengukur kontribusi augmentasi data terhadap peningkatan performa model. Berdasarkan Tabel 1 dan 2 dapat disimpulkan bahwa penggunaan augmentasi secara umum memberikan dampak positif terhadap peningkatan performa model, meskipun hasilnya tidak selalu konsisten pada setiap skenario.

Pada model Inception-v3 tanpa augmentasi, performa terbaik dicapai pada skenario 5 dengan *learning rate* 0.0001 dan *batch size* 32 yang menghasilkan *train accuracy* sebesar 100% dan *test accuracy* sebesar 97.00%. Kemudian, ketika augmentasi diterapkan, Inception-v3 mencapai performa terbaiknya pada skenario 6 dengan *learning rate* 0.0001 dan *batch size* 64 yang menghasilkan *train accuracy* 100% dan *test accuracy* 98.50%. Hal ini menunjukkan bahwa augmentasi mampu meningkatkan kemampuan generalisasi model Inception-v3 sebesar 1.5% pada kondisi terbaiknya. Pada model Inception-v4 tanpa augmentasi, performa terbaik juga diraih pada skenario 5 dengan *learning rate* 0.0001 dan *batch size* 32, menghasilkan *train accuracy* 100% dan *test accuracy* 98.50%, yang setara dengan hasil terbaik Inception-v3 dengan augmentasi. Namun, ketika augmentasi diterapkan pada Inception-v4, hasilnya justru sangat tidak konsisten. Meskipun skenario 6 berhasil menyamai *test accuracy* tertinggi sebesar 98.50% namun skenario dengan *learning rate* sangat kecil (0,00001) mengalami penurunan performa yang drastis, bahkan hingga *test accuracy* 43.50% pada skenario 7. Hal ini menunjukkan bahwa Inception-v4 lebih sensitif terhadap kombinasi augmentasi dan *learning rate* kecil, yang kemungkinan menyebabkan model tidak berhasil konvergen secara optimal.

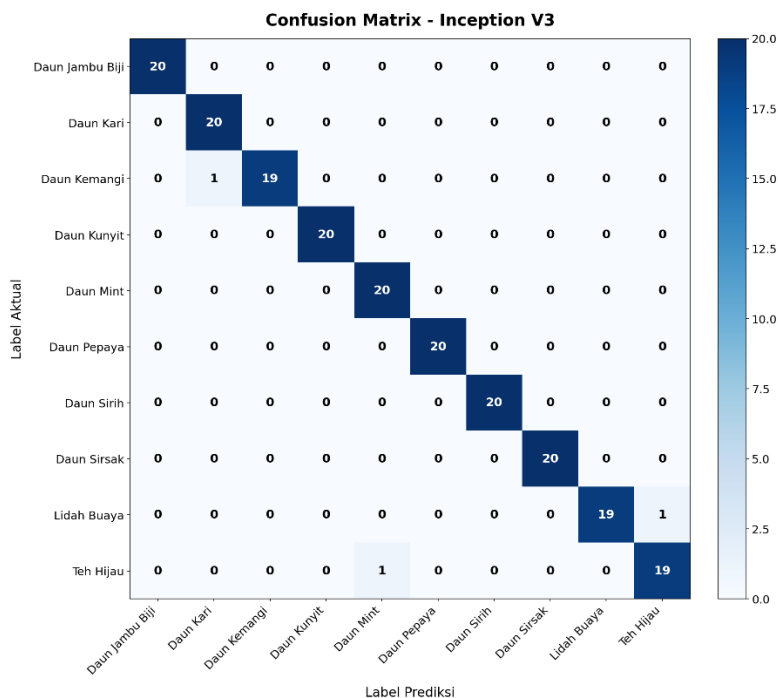
Dilihat dari aspek *learning rate*, nilai 0.0001 secara konsisten menghasilkan performa terbaik pada kedua model. *Learning rate* yang terlalu besar (0.001) cenderung menghasilkan performa yang tidak stabil, sedangkan *learning rate* yang terlalu kecil (0,00001) seringkali menyebabkan penurunan *test accuracy*, terutama pada Inception-v4 dengan augmentasi. Dari sisi *batch size*, ukuran 32 dan 64 sama-sama mampu menghasilkan performa tinggi, namun *batch size* 64 menunjukkan kestabilan yang lebih baik ketika dikombinasikan dengan augmentasi.

Dari segi *overfitting*, hampir seluruh skenario pada kedua model menunjukkan *train accuracy* yang mencapai 100%, namun gap antara *train accuracy* dan *test accuracy* pada skenario-skenario terbaik tergolong kecil, yakni sekitar 1.5% hingga 3%. Gap yang kecil ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak sekadar menghafal data pelatihan (*overfitting*).

Dari segi arsitektural, keunggulan Inception-v3 pada dataset penelitian ini dikarenakan Inception-v4 memiliki arsitektur yang lebih dalam dan kompleks dibandingkan Inception-v3 yang modulnya lebih seragam dan terstruktur, terutama untuk dataset yang terbatas (1000 citra untuk 10 kelas). Ketidakstabilan ini semakin terlihat ketika augmentasi dikombinasikan dengan learning rate sangat kecil (0,00001), di mana kompleksitas Inception-v4 yang lebih tinggi menyebabkan model kesulitan berkonvergensi secara optimal pada jumlah *epoch* yang terbatas, sehingga akurasi yang dihasilkan hanya sekitar 43.5% hingga 51%.

Secara keseluruhan, model terbaik yang dihasilkan adalah Inception-v3 dengan augmentasi pada skenario 6, menggunakan *learning rate* 0.0001, *batch size* 64, dan *epoch* 25. Model ini menghasilkan *test accuracy* tertinggi sebesar 98.50% dengan konsistensi performa yang lebih baik dibandingkan Inception-v4.

4.2. Evaluasi Model Terbaik



Gambar 5. Confusion Matrix Inception-v3 Dengan Augmentasi

Gambar 5 menunjukkan *confusion matrix* untuk model terbaik, yaitu skenario 6 Inception-v3 dengan augmentasi. Dari 10 kelas yang diuji, terdapat 7 kelas yang berhasil diklasifikasikan dengan sempurna, yaitu kelas Daun Jambu Biji, Daun Kari, Daun Kunyit, Daun Mint, Daun Pepaya, Daun Sirih, dan Daun Sirsak. Sementara itu, terdapat 3 kelas yang mengalami kesalahan klasifikasi, yaitu Daun Kemangi, Teh Hijau, dan Lidah Buaya.

Buaya. Ketiga kelas tersebut mengalami 1 kesalahan prediksi. Satu sampel Daun Kemangi diprediksi sebagai Daun Kari, satu sampel Lidah Buaya diprediksi sebagai Teh Hijau, dan satu sampel Teh Hijau diprediksi sebagai Daun Mint.

Tabel 3. Hasil Evaluasi Klasifikasi Inception-v3 Dengan Augmentasi

Kelas	Precision	Recall	F1-Score	Support
Daun Jambu Biji	100.00%	100.00%	100.00%	20
Daun Kari	95.24%	100.00%	97.56%	20
Daun Kemangi	100.00%	95.00%	97.44%	20
Daun Kunyit	100.00%	100.00%	100.00%	20
Daun Mint	95.24%	100.00%	97.56%	20
Daun Pepaya	100.00%	100.00%	100.00%	20
Daun Sirih	100.00%	100.00%	100.00%	20
Daun Sirsak	100.00%	100.00%	100.00%	20
Lidah Buaya	100.00%	95.00%	97.44%	20
Teh Hijau	95.00%	95.00%	95.00%	20
Accuracy			98.50%	200
Macro Average	98.55%	98.50%	98.50%	200
Weighted Average	98.55%	98.50%	98.50%	200

Berdasarkan Tabel 3, dapat dilihat bahwa model menunjukkan *macro average* dan *weighted average* menghasilkan nilai yang sama, yaitu 98.55% karena distribusi *dataset* yang seimbang. Kemudian, model menghasilkan *precision* 98.55%, *recall* 98.50%, dan *F1-score* 98.50% yang menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik dan seimbang untuk seluruh kelas.

4.3. Perbandingan dengan Peneliti Terdahulu

Tahapan ini akan membandingkan hasil terbaik penelitian ini dengan penelitian terdahulu yang menggunakan *dataset* yang sama dan ditunjukkan pada Tabel 4.

Tabel 4. Perbandingan Model Terbaik Dengan Penelitian Terdahulu

Model	Akurasi	Precision	Recall	F1-Score
Inception-v3	98.50%	98.55%	98.50%	98.50%
Inception-v4	98.50%	98.57%	95.00%	98.73%
EfficientNetB7(Arnandito & Sasongko, 2024)	98.00%	98.11%	98.00%	98.00%
AlexNet (Koniady & Rivan, 2025)	74.00%	72.00%	74.00%	70.00%

Berdasarkan Tabel 4, model penelitian ini, yaitu Inception-v3 dan Inception-v4 melampaui kedua model pembanding dari penelitian terdahulu, yaitu EfficientNetB7 dan AlexNet, dengan akurasi 98.50%. Keunggulan Inception-v3 dan Inception-v4 dibandingkan EfficientNetB7 disebabkan oleh perbedaan pendekatan arsitektur, modul Inception pada Inception-v3 dirancang untuk menangkap fitur morfologi daun pada berbagai skala secara bersamaan melalui *multi-scale convolution*, sedangkan EfficientNetB7 mengandalkan *compound scaling* yang meskipun efisien secara komputasi, belum tentu

lebih optimal untuk dataset berskala kecil dengan variasi terbatas. Adapun kesenjangan yang signifikan dengan AlexNet mengonfirmasi bahwa arsitektur CNN yang lebih tua dan dangkal kurang mampu menangkap fitur-fitur kompleks pada citra daun tanaman herbal. Meskipun menghasilkan akurasi yang sama, dari hasil keseluruhan pada Tabel 2, Inception-v3 lebih stabil terhadap variasi *hyperparameter* sehingga menjadikannya sebagai model terbaik dibandingkan Inception-v4. Hal ini menunjukkan bahwa pendekatan *transfer learning* dan augmentasi oleh Inception-v3 dengan parameter *learning rate* 0,0001, *batch size* 64, dan *epoch* 25 merupakan pilihan yang efektif untuk klasifikasi tanaman herbal dengan *dataset* terbatas (1.000 citra untuk 10 kelas).

Penelitian ini secara teoritis membuktikan bahwa arsitektur yang lebih kompleks belum tentu menghasilkan performa lebih baik, khususnya pada dataset terbatas dan domain spesifik seperti klasifikasi tanaman herbal. Dari sisi praktis, model Inception-v3 yang dihasilkan membuka peluang pengembangan sistem identifikasi tanaman herbal otomatis berbasis citra yang dapat diintegrasikan ke dalam aplikasi mobile guna mendukung masyarakat dan tenaga kesehatan dalam proses identifikasi yang lebih cepat dan akurat.

4.4. Keterbatasan Penelitian

Penelitian ini memiliki beberapa keterbatasan penelitian, yaitu jumlah dataset yang terbilang sedikit, yaitu 1.000 citra untuk 10 kelas sehingga keberagaman visual tanaman herbal belum terwakili secara optimal. Kemudian, perbandingan arsitektur CNN masih terbatas pada varian Inception sehingga belum diketahui perbandingan performanya jika diuji dengan arsitektur CNN lain.

5. Kesimpulan

Penelitian ini berhasil mengimplementasikan klasifikasi 10 jenis tanaman herbal berbasis citra daun menggunakan arsitektur *deep learning* Inception-v3 dan Inception-v4 dengan pendekatan *transfer learning* berbasis bobot *pretrained ImageNet*.

Eksperimen dilakukan dengan *hyperparameter tuning* pada variasi *learning rate* dan *batch size*, serta perbandingan antara kondisi dengan dan tanpa augmentasi data sebagai *baseline*. Hasil penelitian menunjukkan bahwa *learning rate* 0.0001 secara konsisten menghasilkan performa terbaik pada kedua arsitektur. Augmentasi data memberikan dampak positif terhadap kemampuan generalisasi model, khususnya pada Inception-v3 yang mengalami peningkatan *test accuracy* sebesar 1.5% dibandingkan kondisi tanpa augmentasi. Sebaliknya, Inception-v4 menunjukkan sensitivitas yang lebih tinggi terhadap kombinasi augmentasi dan *learning rate* kecil, sehingga menghasilkan performa yang tidak konsisten antar skenario.

Model terbaik yang dihasilkan adalah Inception-v3 dengan augmentasi pada skenario 6, menggunakan *learning rate* 0.0001, *batch size* 64, dan *epoch* 25, dengan *test*

accuracy 98.50%, *precision* 98.55%, *recall* 98.50%, dan *F1-score* 98.50%. Dari 10 kelas yang diklasifikasikan, 7 kelas berhasil diprediksi dengan sempurna, sementara 3 kelas mengalami masing-masing 1 kesalahan prediksi yang kemungkinan disebabkan oleh kemiripan visual antar daun.

Dibandingkan dengan penelitian terdahulu yang menggunakan dataset yang sama, model Inception-v3 dan Inception-v4 dalam penelitian ini berhasil melampaui EfficientNetB7 (Arnandito & Sasongko, 2024) dengan selisih 0.50% dan AlexNet (Koniady & Rivan, 2025) dengan selisih yang cukup signifikan sebesar 24.50%. Hal ini membuktikan bahwa kombinasi *transfer learning*, augmentasi data, dan *hyperparameter tuning* yang tepat mampu menghasilkan model klasifikasi tanaman herbal yang akurat meskipun dengan dataset yang terbatas, yaitu 1.000 citra untuk 10 kelas.

Sebagai prospek pengembangan, penelitian selanjutnya dapat memperluas jumlah kelas tanaman herbal dan penggunaan dataset yang lebih besar untuk meningkatkan kemampuan generalisasi model. Kemudian, mengeksplorasi arsitektur yang lebih modern, seperti EfficientNet-v2 atau Vision Transformer (ViT). Selain itu, dapat juga dilakukan integrasi model ke dalam aplikasi *mobile* berbasis pengenalan citra daun secara *real-time* supaya dapat dimanfaatkan secara langsung oleh masyarakat.

6. Ucapan Terima Kasih

Saya mengucapkan puji syukur kepada Tuhan Yang Maha Esa, serta kepada semua pihak yang terlibat pada penelitian ini terutama *co-author* dari Universitas Multi Data Palembang karena telah mendukung dan membimbing selama proses penelitian ini berlangsung hingga selesai.

7. Pernyataan Penulis

Penulis menyatakan bahwa tidak ada konflik kepentingan terkait publikasi artikel ini. Penulis menyatakan bahwa data dan makalah bebas dari plagiarisme serta penulis bertanggung jawab secara penuh atas keaslian artikel.

Bibliografi

- Adelia, D., Fitri, Z., & Agusniar, C. (2025). Deteksi Daun Herbal Dan Beracun Menggunakan Convolutional Neural Network Untuk Klasifikasi Tanaman Herbal Dan Beracun. *RABIT: Jurnal Teknologi dan Sistem Informasi Univrab*, 10(2), 204–216.
- Adiningsi, S., & Saputra, R. A. (2023). Identifikasi Jenis Daun Tanaman Obat Menggunakan Metode Convolutional Neural Network (CNN) Model VGG16. *Jurnal Informatika Polinema*, 9(4), 451–460.
- Ahmad, M. H., Hana, F. M., Pratama, T. G., & Aulida, H. (2023). Klasifikasi Empat Jenis Daun Herbal Menggunakan Metode Convolutional Neural Network. *Jurnal*

- Ilmu Komputer dan Matematika*, 4(2), 69–76.
- Alya, R. F., Wibowo, M., & Paradise. (2023). Classification of Batik Motif Using Transfer Learning on Convolutional Neural Network (CNN). *Jurnal Teknik Informatika (JUTIF)*, 4(1), 161–170.
- Andreas, E., & Widhiarso, W. (2023). Klasifikasi Penyakit Mata Katarak Menggunakan Convolutional Neural Network Dengan Arsitektur Inception V3. *MDP Student Conference (MSC) 2023*, 107–113.
- Arnandito, S., & Sasongko, T. B. (2024). Comparison of EfficientNetB7 and MobileNetV2 in Herbal Plant Species Classification Using Convolutional Neural Networks. *Journal of Applied Informatics and Computing*, 8(1), 176–185.
- Azizah, N., Nuswantoro, S. A., Jaya, F., R, R. S., & Ansori. (2024). Algoritma Deep Learning Untuk Pengenalan Gambar Jenis Daun. *Anterior Journal*, 23(III), 161–166.
- Azzahra, Z. F. (2025). Analisis Pemanfaatan Tanaman Obat Terhadap Penyembuhan Penyakit. *Maliki Interdisciplinary Journal (MIJ)*, 3(April), 545–555.
- Cakmak, Y., & Maman, A. (2025). Deep Learning for Early Diagnosis of Lung Cancer. *Computational Systems and Artificial Intelligence*, 1(1), 20–25.
- Christian, J., & Idrus, S. I. Al. (2023). Introduction to Citrus Fruit Ripens Using the Deep Learning Convolutional Neural Network (CNN) Learning Method. *Asian Journal of Applied Education (AJAE)*, 2(3), 459–470.
- Dewi, I. A., & G, M. G. (2023). Implementasi Hyperparameter Optimizer Pada InceptionV4 Untuk Deteksi Penyakit Karat Kedelai. *E-Proceeding FTI*, 1–11. <https://eproceeding.itenas.ac.id/index.php/fti/article/view/3175>
- Hanggoro, D. B. D. (2025). Analisis Komparatif Arsitektur Deep Learning Untuk Aplikasi Computer Vision : Studi Literature Review. *Jurnal Komputer Teknologi Informasi Sistem Komputer*, 4(2), 1001–1008.
- Huda, N., Mahiruna, A., Sulistijanti, W., & Santi, R. C. N. (2023). Performance Analysis of InceptionV3 Convolutional Network Used for Grapevine Leaves Varieties Classification. *Jurnal Sains Komputer Dan Teknologi*, 5(2), 48–54.
- Ichwan, M., & Sumantri, H. (2024). Evaluasi Kinerja Model Inception Resnet-V2 dan Inception-V4 dalam Mengklasifikasi Kualitas Biji Kakao. *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, 9(1), 25–41.
- Kartarina, Islamiah, N., Supatmiwati, D., Zulfiqri, M., Triwijoyo, B. K., & Amrullaj, R. (2025). Image Classification of Medicinal Plants Using Inception V3 and CNN : A Novel Implementation. *International Journal of Electronics and Communications System*, 5(2), 143–158. <https://doi.org/10.24042/ijecs.v5i2.27930>
- Kasim, N., Fadilah, M. B., Hidayat, W. Al, & Saputra, R. A. (2024). Klasifikasi Jenis Tanaman Herbal Berdasarkan Citra Menggunakan Metode Convolution Neural Network (CNN). *Jurnal TEKNO KOMPAK*, 19(1), 64–78.
- Koniady, D. D., & Rivan, M. E. Al. (2025). Klasifikasi Jenis Daun Tanaman Herbal Menggunakan Metode Convolutional Neural Network Dengan Arsitektur AlexNet. *Jurnal Informatika Dan Teknologi (INTECH)*, 6(2), 243–252.
- Meilani, C., Ambarwati, R., Saputri, D., & Fujianto. (2025). Klasifikasi Jenis Tanaman Obat Herbal Berdasarkan Ciri Daun Menggunakan K-NN. *Jurnal Pengembangan Teknologi Informasi dan Komunikasi*, 3(2), 34–40.

- <https://doi.org/10.52060/juptik.v3i2.3028>
- Meiriyama, Devella, S., & Adelfi, S. M. (2022). Klasifikasi Daun Herbal Berdasarkan Fitur Bentuk Dan Tekstur Menggunakan KNN. *Jurnal Teknik Informatika dan Sistem Informasi*, 9(3).
- Munaeni, W., Mainassy, M. C., Puspitasari, D., Susanti, L., Endriyatno, N. C., Yuniastuti, A., Wiradnyani, N. K., Fauziah, P. N., Achmad, A. F., Rohmah, M. K., Rahman, I. F., Yulianti, R., Cesa, F. Y., Hendra, G. A., & Rollando. (2022). *Perkembangan dan Manfaat Obat Herbal Sebagai Fitoterapi* (M. T. K. Swandari & M. A. E. Mayer (ed.)). CV. Tohar Media.
- Nandini, B., & Puviarasi, R. (2021). Detection of Skin Cancer using Inception V3 And Inception V4 Convolutional Neural Network (CNN) For Accuracy Improvement. *GEINTEC*, 11(4), 1138–1148.
- Nazir, M. S., Khan, U. G., Mohiyuddin, A., Reshan, M. S. Al, Shaikh, A., Rizwan, M., & Davidekova, M. (2022). A Novel CNN-Inception-V4-Based Hybrid Approach for Classification of Breast Cancer in Mammogram Images. *Wireless Communications and Mobile Computing*, 2022, 10.
- Nurdiansyah, Muliadi, Herteno, R., Kartini, D., & Budiman, I. (2024). Implementasi Metode Principal Component Analysis (PCA) Dan Modified K-Nearest Neighbor Pada Klasifikasi Citra Daun Tanaman Herbal. *Jurnal MNEMONIC*, 7(1), 1–9.
- Nurdin, A., Kartika, D. S. Y., & Najaf, A. R. E. (2024). Klasifikasi Penyakit Daun Tomat Dengan Metode Convolutional Neural Network Menggunakan Arsitektur Inception-V3. *Jurnal Ilmiah Informatika (JIF)*, 12(2).
- Pratama, A. P., Jumadi, & Nurlatifah, E. (2025). Klasifikasi Ras Kucing Dengan Pendekatan Convolutional Neural Networks Menggunakan Arsitektur Inception V4. *SMATIKA: STIKI Informatika Jurnal*, 15(2), 248–257.
- Pratiwi, V. R., & Pardede, J. (2022). Image Captioning Menggunakan Metode Inception-V3 dan Transformer. *Prosiding Diseminasi FTI*, 1–14.
- Rastogi, D., Johri, P., & Tiwari, V. (2023). Brain Tumor Detection and Localization : An Inception V3 - Based Classification Followed By RESUNET-Based Segmentation Approach. *International Journal of Mathematical, Engineering and Management Sciences*, 8(2), 336–352.
- Rozi, M. I. F., Adiwijaya, N. O., & Swasono, D. I. (2023). Identifikasi Kinerja Arsitektur Transfer Learning VGG16 , ResNet-50 , dan Inception-V3 Dalam Pengklasifikasian Citra Penyakit Daun Tomat. *Jurnal Riset Rekayasa Elektro*, 5(2), 145–154.
- Sujiwanto, A. R., Prawirodirjo, R. R. B. P., & Palupingsih, P. (2023). Analisis Perbandingan Performa Model Klasifikasi Kesehatan Daun Tomat Menggunakan Arsitektur VGG , MobileNet , dan Inception V3. *Jurnal Ilmu Komputer Agri-Informatika*, 10(1), 98–110.
- Tanesab, F. I., Laatrehe, C. Y., & Wuarlela, M. A. (2025). Penerapan Metode CNN Dalam Mengklasifikasi Jenis Penyakit Pada Daun Mangga Menggunakan Arsitektur InceptionV3. *Jurnal Penelitian Nusantara*, 1(8), 265–275.
- Trihardianingsih, L., Sunyoto, A., & Hidayat, T. (2023). Classification of Tea Leaf Diseases Based on ResNet-50 and Inception V3. *Sinkron: Jurnal dan Penelitian*

- Teknik Informatika*, 7(3), 1564–1573.
- Tyassari, W., Jusman, Y., Riyadi, S., & Sulaiman, S. N. (2022). Classification of Cervical Precancerous Cell of ThinPrep Images Based on Deep Learning Model AlexNet and InceptionV3. *IEEE 11th International Conference on Communication Systems and Network Technologies (CSNT)*, 276–281. <https://doi.org/10.1109/CSNT54456.2022.9787658>
- Ungkawa, U., & Hakim, G. Al. (2023). Klasifikasi Warna pada Kematangan Buah Kopi Kuning Menggunakan Metode CNN Inception V3. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, dan Teknik Elektronika*, 11(3), 731–743.
- Wahid, M. I., Mustamin, S. A., & Lawi, A. (2021). Identifikasi Dan Klasifikasi Citra Penyakit Daun Tomat Menggunakan Arsitektur Inception V4. *Konferensi Nasional Ilmu Komputer (KONIK)*, 257–264.
- Wicaksono, A. B., & Hartato, B. P. (2025). Analisis Performa Arsitektur CNN InceptionV3 Dan VGG16 Dalam Klasifikasi Deteksi Kanker Otak. *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, 10(2), 938–948.
- Widyatama, I. D. G. S., Sudipa, I. G. I., Fittryani, Y. P., Wulandari, D. A. P., & Jayanegara, I. N. (2025). Convolutional Neural Network Algorithm Implementation for Classifying Traditional Wood Carving Motifs of Patra Bali. *Sinkron: Jurnal dan Penelitian Teknik Informatika*, 9(3), 1084–1093.