

TESIS
**PENERAPAN *TRANSFER LEARNING* DENGAN *INCEPTION-
V3* DAN *EFFICIENTNET-B4* PADA STUDI KASUS
KLASIFIKASI PENYAKIT PADA DAUN SINGKONG**



disusun oleh

TRI ANTON

22.55.1221

Konsentrasi : Business Intelligence

**FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2026

TESIS
PENERAPAN *TRANSFER LEARNING* DENGAN *INCEPTION-V3*
DAN *EFFICIENTNET-B4* PADA STUDI KASUS KLASIFIKASI
PENYAKIT PADA DAUN SINGKONG

APPLICATION OF TRANSFER LEARNING WITH *INCEPTION-*
***V3* AND *EFFICIENTNET-B4* IN A CASE STUDY OF CASSAVA**
LEAF CLASSIFICATION

Diajukan untuk memenuhi salah satu syarat mencapai derajat Pascasarjana
Program Studi Teknik Informatika



disusun oleh

TRI ANTON

22.55.1221

Konsentrasi : Business Intelligence

FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2026

HALAMAN PERSETUJUAN

**PENERAPAN *TRANSFER LEARNING* DENGAN *INCEPTION-V3* DAN
EFFICIENTNET-B4 PADA STUDI KASUS KLASIFIKASI PENYAKIT PADA
DAUN SINGKONG**

**APPLICATION OF TRANSFER LEARNING WITH *INCEPTION-V3* AND
EFFICIENTNET-B4 IN A CASE STUDY OF CASSAVA LEAF
CLASSIFICATION**

yang disusun dan diajukan oleh

Tri Anton

22.55.1221

telah disetujui oleh Dosen Pembimbing Tesis
pada tanggal 25 Januari 2024

Pembimbing Utama



Prof. Arief Setyanto, S.SI., M.T., Ph.D.

NIK. 190302036

HALAMAN PENGESAHAN

PENERAPAN *TRANSFER LEARNING* DENGAN *INCEPTION-V3* DAN
EFFICIENTNET-B4 PADA STUDI KASUS KLASIFIKASI PENYAKIT PADA
DAUN SINGKONG

APPLICATION OF TRANSFER LEARNING WITH *INCEPTION-V3* AND
EFFICIENTNET-B4 IN A CASE STUDY OF CASSAVA LEAF
CLASSIFICATION

yang disusun dan diajukan oleh

Tri Anton

22.55.1221

Telah dipertahankan di depan Dewan Penguji
pada tanggal 02 Desember 2025

Susunan Dewan Penguji

Nama Penguji

Tanda Tangan

Robert Marco, S.T., M.T., Ph.D.
NIK. 190302228



Dr. Andi Sunyoto, S.Kom., M.Kom.
NIK. 190302052



Prof. Arief Setyanto, S.Si., M.T., Ph.D.
NIK. 190302036



Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer
Tanggal 02 Desember 2025

DEKAN FAKULTAS ILMU KOMPUTER



Prof. Dr. Kusriani, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Tri Anton
NIM : 22.55.1221

Menyatakan bahwa Tesis dengan judul berikut:

Penerapan Transfer Learning Dengan Inception-V3 dan Efficientnet-B4 Pada Studi Kasus Klasifikasi Penyakit Pada Daun Singkong

Dosen Pembimbing Utama : Prof. Arief Setyanto, S.Si., M.T., Ph.D.

Dosen Pembimbing Pendamping : Dhani Ariatmanto, M.Kom., Ph.D.

1. Karya tulis ini adalah benar-benar **ASLI** dan **BELUM PERNAH** diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya.
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian **SAYA** sendiri, tanpa bantuan pihak lain kecuali arahan dari Dosen Pembimbing.
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini.
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab **SAYA**, bukan tanggung jawab Universitas AMIKOM Yogyakarta.
5. Pernyataan ini **SAYA** buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka **SAYA** bersedia menerima **SANKSI AKADEMIK** dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi.

Yogyakarta, < 02 Desember 2025 >

Yang Menyatakan,



Tri Anton

HALAMAN PERSEMBAHAN

Alhamdulillah, puja dan puji syukur kepada Allah SWT, berkah dan limpahan rahmat serta karunia nya sehingga saya dapat menyelesaikan Tesis ini dengan baik. Tesis ini saya persembahkan kepada:

1. Allah SWT yang telah memberikan rahmat, nikmat serta hidayahnya sehingga saya bisa menyelesaikan skripsi ini dengan baik.
2. Kedua orang tua ku Alm. bapak dan ibu yang selalu memberikan doa, dukungan serta semangat sehingga saya dapat menyelesaikan skripsi ini.
3. Bapak Prof. Dr. Arief Setyanto, S.Si., M.T. dan Dhani Ariatmanto, M.Kom., Ph.D. selaku dosen pembimbing yang telah memberikan saran, bantuan, masukan dan bimbingan untuk menyelesaikan Tesis ini.
4. Kepada teman-teman Seperjuangan MTI, terimakasih kepada kalian yang telah menjadi teman saya semasa kuliah serta kenangan yang telah kita lalui.
5. Dan seluruh pihak yang sudah membantu saya yang tidak dapat saya sebutkan satu persatu, saya ucapkan banyak terimakasih

KATA PENGANTAR

Assalamu 'alaikum Wr. Wb

Puji syukur kita ucapkan kehadirat Allah SWT, yang telah memberikan rahmat dan hidayah nya sehingga penulis dapat menyelesaikan tesis ini. Shalawat dan salam tidak lupa kita ucapkan kepada junjungan kita nabi Muhammad SAW, serta keluarga dan para sahabatnya yang memberi syafaatnya kepada kita semua sehingga kita dalam perlindungannya.

Tesis ini disusun sebagai salah satu syarat kelulusan mahasiswa UNIVERSITAS AMIKOM YOGYAKARTA. Selain itu juga merupakan bukti mahasiswa menyelesaikan kuliah jenjang Strata-2 dan untuk memperoleh gelar Magister komputer. Keberhasilan ini tidak lepas dari bantuan berbagai pihak. Dalam kesempatannya, penulis berterima kasih:

1. Bapak Prof. Dr. M Suyanto, MM, selaku rektor UNIVERSITAS AMIKOM YOGYAKARTA.
2. Bapak Dhani Ariatmanto, M.Kom., Ph.D. Selaku Kaprodi S2-PJJ Informatika UNIVERSITAS AMIKOM YOGYAKARTA.
3. Bapak Prof. Dr. Arief Setyanto, S.Si., M.T. dan Dhani Ariatmanto, M.Kom., Ph.D. selaku dosen pembimbing yang telah memberikan saran, bantuan, masukan dan bimbingan untuk menyelesaikan Tesis ini.
4. Bapak dan Ibu dosen UNIVERSITAS AMIKOM YOGYAKARTA yang telah memberikan ilmu saat perkuliahan.
5. Semua pihak yang membantu baik dukungan moral, pikiran dan tenaga dalam penyelesaian tesis ini.

Ucapan terima kasih juga penulis sampaikan kepada pihak yang tidak bisa disebutkan satu per-satu semoga Allah SWT membalas kebaikan dan melimpahkan rahmat dan hidayah nya kepada kita semua. Penulis telah berupaya dengan semaksimal mungkin dalam penyelsaian tesis ini, namun penulis menyadari masih banyak

kekurangan baik dari segi isi maupun tata Bahasa, untuk itu penulis mengharapkan kritik dan saran yang bersifat membangun sehingga berguna bagi kesempurnaan tesis ini. Akhirnya dengan segala kerendahan hati penulis berharap dan berdoa semoga tesis ini dapat memberikan manfaat bagi semua pihak yang membutuhkan. Aamiin.

Wassalamu'alaikum Wr. Wb

Yogyakarta, 15 Juli 2025




Tri Anton



DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PERSETUJUAN.....	ii
HALAMAN PENGESAHAN	iii
HALAMAN PERNYATAAN KEASLIAN TESIS	iv
HALAMAN PERSEMBAHAN	v
KATA PENGANTAR	vi
DAFTAR ISI.....	viii
DAFTAR TABEL.....	x
DAFTAR GAMBAR.....	xi
INTISARI.....	xii
ABSTRACT.....	xiii
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	8
1.3 Batasan Masalah	9
1.4 Tujuan Penelitian	9
1.5 Manfaat Penelitian	10
BAB 2 TINJAUAN PUSTAKA	11
2.1 Tjauan Pustaka.....	11
2.2 Keaslian Penelitian	17
2.3 Landasan Teori	30
BAB 3 METODE PENELITIAN	44
3.1 Jenis, Sifat, dan Pendekatan Penelitian.....	44
3.2 Metode Pengumpulan Data.....	45
3.3 Metode Analisis Data.....	48
3.4 Alur Penelitian	49
3.5 Pembagian Data	53
3.6 Pembangunan Model	53
3.7 Evaluasi Model	55
BAB 4 HASIL PENELITIAN DAN PEMBAHASAN	56
4.1 Argumentasi Gambar.....	56
4.2 Prapemrosesan Gambar	56
4.3 Pembagian Data	57
4.4 Pembangunan Model	57

4.5 Tuning Hyperparameter.....	59
4.6 Pelatihan dan Evaluasi.....	59
4.7 Hasil Penelitian.....	60
4.8 Distribusi Dataset.....	65
BAB 5 PENUTUP.....	68
5.1 Kesimpulan.....	68
5.2 Saran.....	69
DAFTAR PUSTAKA.....	71



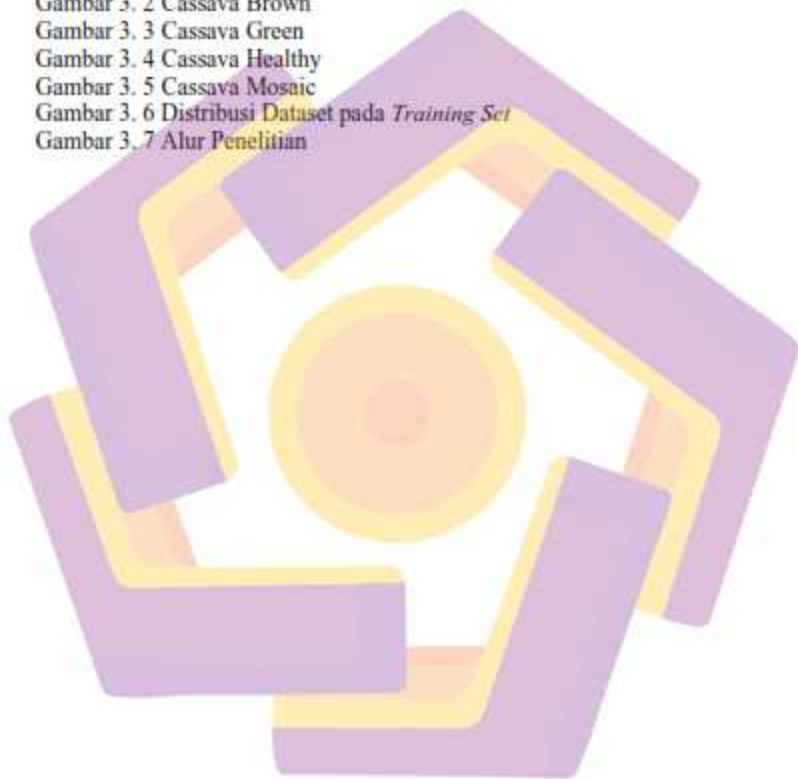
DAFTAR TABEL

Tabel 2. 1 Penerapan <i>Transfer Learning</i> Dengan <i>Inception-V3</i> Dan	17
Tabel 2. 2 <i>Confusion Matrix</i>	41
Tabel 3. 1 Parameter Algoritma	54
Tabel 4. 1 Hasil Penelitian	60
Tabel 4. 2 Dataset Sebelum Augmentasi	65
Tabel 4. 3 Dataset Setelah Augmentasi	65



DAFTAR GAMBAR

Gambar 2. 1 Struktur Jaringan pada <i>Inception-V3</i>	37
Gambar 2. 2 Struktur Jaringan pada <i>EfficientNet</i>	39
Gambar 3. 1 Cassava Bacterial	46
Gambar 3. 2 Cassava Brown	46
Gambar 3. 3 Cassava Green	46
Gambar 3. 4 Cassava Healthy	46
Gambar 3. 5 Cassava Mosaic	46
Gambar 3. 6 Distribusi Dataset pada <i>Training Set</i>	47
Gambar 3. 7 Alur Penelitian	50



INTISARI

Singkong adalah tanaman yang memiliki permintaan yang tinggi di Indonesia, ditandai dengan peningkatan tingkat produksi seiring waktu. Selain kuantitas, kualitas tanaman harus dijaga, salah satunya dengan memperhatikan gejala penyakit. Gejala penyakit yang timbul pada daun singkong dapat dideteksi dengan inspeksi visual. Tetapi, diperlukan pengetahuan lebih untuk membedakan gejala suatu penyakit dengan penyakit lainnya. Salah satu solusi dari masalah ini adalah pemanfaatan convolutional neural networks (CNN) untuk klasifikasi penyakit. Penulis menggunakan model CNN untuk masalah ini. Parameter penilai kinerja model CNN yang digunakan adalah akurasi, presisi, recall, dan F1-score. penelitian ini akan menggunakan dua arsitektur pada transfer learning, yaitu EfficientNet-B4 dan Inception-V3. Kedua arsitektur ini masih jarang digunakan pada studi kasus terkait. Tujuan peningkatan jumlah parameter ini adalah untuk menemukan konfigurasi optimal pada optimizer dan learning rate yang dapat memaksimalkan performa model. Dengan peningkatan jumlah parameter dan pemanfaatan dua arsitektur pada transfer learning, diharapkan kemampuan model dalam menangani kompleksitas masalah klasifikasi gambar daun singkong penyakit dapat ditingkatkan. Fokus penelitian ini juga akan difokuskan pada penerapan arsitektur EfficientNet-B4 dan Inception V3 dengan skema hyperparameter tuning untuk meningkatkan performa model. Oleh karena itu, penelitian ini diharapkan dapat memberikan kontribusi yang lebih unggul dalam pengembangan CNN untuk klasifikasi penyakit pada daun singkong, dengan performa yang lebih baik dan lebih akurat.

Kata kunci: penyakit singkong, convolutional neural network, computer vision, image classification, densenet.

ABSTRACT

Cassava is a crop that has high demand in Indonesia, marked by increasing production levels over time. In addition to quantity, crop quality must be maintained, one of which is by paying attention to disease symptoms. Disease symptoms that appear on cassava leaves can be detected by visual inspection. However, more knowledge is needed to distinguish the symptoms of one disease from another. One solution to this problem is the use of convolutional neural networks (CNN) for disease classification. The author uses a CNN model for this problem. The performance assessment parameters of the CNN model used are accuracy, precision, recall, and F1-score. This study will use two architectures in transfer learning, namely EfficientNet B4 and Inception-V3. Both of these architectures are still rarely used in related case studies. The purpose of increasing the number of parameters is to find the optimal configuration of the optimizer and learning rate that can maximize model performance. By increasing the number of parameters and utilizing two architectures in transfer learning, it is hoped that the model's ability to handle the complexity of the problem of classifying images of cassava leaves with disease can be improved. The focus of this study will also be focused on the application of the EfficientNet-B4 and Inception-V3 architectures with a hyperparameter tuning scheme to improve model performance. Therefore, this research is expected to provide a superior contribution in the development of CNN for disease classification in cassava leaves, with better and more accurate performance.

Keyword: *cassava diseases, convolutional neural networks, computer vision, image classification, densenet.*

BAB I

PENDAHULUAN

1.1 Latar Belakang

Tanaman singkong (*Manihotesculenta Crantz*) merupakan salah satu komoditas pertanian yang memiliki peran strategis dalam memenuhi kebutuhan pangan masyarakat Indonesia [1]. Selain sebagai sumber karbohidrat yang signifikan, singkong juga memiliki potensi untuk diolah menjadi berbagai produk olahan dengan nilai tambah tinggi, seperti tepung tapioka, keripik singkong, dan makanan ringan lainnya. Saat ini, Indonesia menduduki peringkat keempat sebagai produsen singkong terbesar di dunia. Peringkat pertama ditempati oleh Nigeria dengan produksi sebesar 57 juta ton, diikuti oleh Thailand dengan 30 juta ton, Brasil dengan 23 juta ton, dan Indonesia dengan jumlah produksi mencapai 19-20 juta ton. Sentra produksi singkong di Indonesia tersebar di 13 provinsi, dengan lima provinsi utama penghasil singkong meliputi Lampung, Jawa Tengah, Jawa Timur, Jawa Barat, dan DI Yogyakarta [2]. Menurut data dari Ditjen Tanaman Pangan, luas areal penanaman singkong pada tahun 2019 mencapai 628.305 hektar, dengan produksi sekitar 16,35 juta ton [2]. Program pengembangan untuk tahun 2020 mencakup luas areal penanaman sebesar 11.175 hektar.

Meski demikian, di tengah potensi besar yang dimiliki, tanaman singkong juga menghadapi tantangan serius, terutama terkait dengan penyakit yang dapat memengaruhi produktivitas dan kualitas hasil [3]. Penyakit pada tanaman singkong, seperti antraknosa, bercak daun, dan virus daun kering, dapat merugikan petani dan

berpotensi menghambat pertumbuhan industri singkong. Salah satu tantangan utama dalam pengelolaan penyakit ini adalah deteksi dini penyakit, yang seringkali membutuhkan tenaga ahli dan waktu yang lama. Selain itu, akurasi deteksi dengan metode konvensional terkadang kurang memadai, terutama ketika menghadapi variasi gejala penyakit yang serupa namun disebabkan oleh patogen yang berbeda [4]. Pemahaman mendalam tentang penyakit-penyakit ini dan implementasi strategi pengelolaan penyakit yang efektif menjadi krusial untuk menjaga keberlanjutan produksi singkong [5].

Dalam upaya menghadapi tantangan ini, penerapan teknologi modern, seperti kecerdasan buatan, menjadi semakin relevan. Pemanfaatan algoritma kecerdasan buatan dapat memberikan deteksi dini terhadap gejala penyakit, memungkinkan petani untuk merespons lebih cepat dan menerapkan langkah-langkah pengendalian yang efektif [6]. Integrasi teknologi modern ini diharapkan tidak hanya memitigasi risiko penyakit pada tanaman singkong, tetapi juga meningkatkan efisiensi dan produktivitas sektor pertanian secara keseluruhan [7].

Dalam beberapa dekade terakhir, kemajuan teknologi kecerdasan buatan, terutama dengan penerapan *Deep Learning* (DL), telah membuka peluang baru dalam transformasi sektor pertanian [8]. DL, khususnya dengan algoritma yang kuat seperti *Convolutional Neural Network* (CNN), telah menjadi algoritma yang populer dan unggul dalam berbagai aplikasi klasifikasi citra, termasuk deteksi penyakit tanaman [9]. CNN memiliki kemampuan untuk secara otomatis mengekstraksi fitur dari gambar daun singkong tanpa memerlukan teknik pra-pemrosesan yang rumit, yang menjadikannya ideal untuk klasifikasi penyakit

tanaman singkong [5]. Namun, CNN juga memiliki kelemahan. Salah satu kelemahannya adalah memerlukan jumlah data yang sangat besar dan beragam untuk pelatihan agar dapat bekerja secara efektif. Jika dataset yang digunakan tidak mencukupi atau tidak beragam, CNN berpotensi mengalami *Overfitting*, yaitu model hanya bekerja baik pada data pelatihan tetapi tidak mampu mengenali data baru dengan baik [10].

Dalam ranah pertanian, terutama pada budidaya singkong di Indonesia, sering kali terdapat kesulitan dalam mendapatkan dataset gambar yang memadai dan beraneka ragam. Kendala ini menjadi salah satu hambatan utama dalam mengimplementasikan DL secara langsung. Oleh karena itu, *Transfer learning* menjadi opsi yang efisien untuk mengatasi keterbatasan ini [11]. Dengan memanfaatkan DL yang telah terlatih pada dataset yang luas dan beragam dapat dimanfaatkan untuk tugas klasifikasi gambar daun singkong yang spesifik [12]. Pendekatan ini memungkinkan pencapaian tingkat akurasi yang tinggi dalam mengidentifikasi gejala penyakit pada tanaman singkong, meskipun data pelatihan yang tersedia terbatas. Dengan menyatukan langkah-langkah ini, fokus diarahkan ke implementasi teknologi kecerdasan buatan yang responsif dan efisien dalam mendukung petani serta mengurangi risiko penyakit pada tanaman singkong. Dengan memanfaatkan potensi *transfer learning*, diharapkan dapat mengatasi kekurangan data dan menghadirkan solusi berkelanjutan untuk meningkatkan ketahanan pertanian serta kesejahteraan petani di Indonesia, sejalan dengan latar belakang tantangan penyakit pada tanaman singkong.

Penelitian terhadap klasifikasi gambar singkong menggunakan *transfer learning* telah dilakukan pada beberapa penelitian sebelumnya. Alex dan rekan-rekan pada tahun 2022 melakukan penelitian terkait klasifikasi daun singkong dengan pendekatan *transfer learning* [13]. Penulis melakukan pelatihan model menggunakan empat jenis arsitektur (MobileNet V1, MobNet V2, MobNet V3, dan CropNet), dua jenis dataset (*Balance* dan *Unbalance*), dan tiga jenis skenario yaitu perubahan *optimizer* (Adam, Nadam, dan RMSProp), *Batch Size* (16, 32, dan 64), dan *Learning Rate* (0.01, 0.001, dan 0.0001). Hasil terbaik yang didapatkan pada penelitian ini yaitu menggunakan arsitektur CropNet dengan dataset unbalanced dan juga skenario seperti berikut *optimizer* Nadam, *Learning Rate* 0.001, dan *Batch Size* 32 dengan hasil akurasi sebesar 87.47%. Arsitektur terbaik yang digunakan pada citra balanced adalah MobileNet V3 dengan hasil akurasi sebesar 83.54%. Hasil tersebut menunjukkan perbandingan antara arsitektur terbaik pada dataset unbalanced dan balanced.knp

Selain itu, Aditya dan rekan-rekan melakukan penelitian yang serupa dengan pendekatan *transfer learning* juga [5]. Dilakukan pelatihan model-model dasar, yakni model-model CNN berbasis DenseNet-121 dengan *optimizer* dan *Learning Rate* yang berbeda untuk masing-masing model. Model-model ini dilatih menggunakan *Learning Rate* 0,01; 0,001; dan 0,0001. *Optimizer* yang digunakan untuk masing-masing *Learning Rate* adalah Adam, RMSprop, dan SGD. Pelatihan model CNN menggunakan *Batch Size* sebesar 64 dan dengan epoch sebanyak 25.. Dari hasil pengujian, didapatkan bahwa model CNN dengan arsitektur dasar DenseNet-169, *optimizer* RMSprop, dan *Learning Rate* 0,0001 memiliki performa

terbaik dibanding dengan variasi model lainnya. Dengan menggunakan metode augmentasi tertentu pada data latih, model ini memiliki akurasi training 98,73%, akurasi validation 81,67%, dan akurasi testing 82%. Meskipun memiliki akurasi yang cukup tinggi, performa model untuk tiap kelas tidak seimbang. Salah satu faktor utama dari masalah ini adalah ketidakseimbangan jumlah gambar untuk tiap kelas pada dataset yang digunakan.

Dalam penelitian ini, diajukan penggunaan jumlah parameter arsitektur yang diperluas untuk meningkatkan kinerja model yang dikonstruksi. Sebelumnya, beberapa penelitian yang disebutkan telah melibatkan optimasi arsitektur, tetapi belum menggunakan teknik *grid search* yang sistematis untuk menentukan konfigurasi *hyperparameter* secara menyeluruh. Oleh karena itu, penelitian ini akan mengusung ide penggunaan *grid search* dalam kombinasi dengan dua arsitektur transfer learning, yaitu *EfficientNet-B4* dan *Inception-V3*. Kedua arsitektur ini masih jarang digunakan pada studi kasus terkait klasifikasi penyakit pada daun singkong. Tujuan utama dari penelitian ini adalah untuk menemukan konfigurasi optimal dari *hyperparameter*, seperti *optimizer* dan *Learning Rate*, yang dapat memaksimalkan performa model. *Optimizer* adalah algoritma yang digunakan untuk memperbarui bobot atau parameter model CNN selama pelatihan, dengan tujuan meminimalkan *loss function* dan meningkatkan akurasi model. Sementara itu, *Learning Rate* adalah parameter yang mengatur seberapa besar perubahan yang diterapkan oleh *optimizer* saat memperbarui bobot model CNN. Keduanya merupakan elemen krusial dalam pelatihan CNN dan perlu dipilih dengan cermat

untuk mencapai keseimbangan optimal antara kecepatan pelatihan dan akurasi model yang dihasilkan.

Meskipun berbagai penelitian sebelumnya telah menggunakan arsitektur CNN populer seperti MobileNet, VGG, ResNet, dan DenseNet dalam mendeteksi penyakit daun singkong, masing-masing memiliki keterbatasan. MobileNet unggul dalam efisiensi komputasi, namun akurasinya relatif lebih rendah pada dataset dengan kompleksitas tinggi. VGGNet memiliki performa yang stabil, tetapi membutuhkan jumlah parameter yang sangat besar, sehingga tidak efisien untuk implementasi skala luas. ResNet mampu mencapai akurasi tinggi pada dataset besar, namun berisiko mengalami *overfitting* bila data terbatas. DenseNet dapat memanfaatkan kembali fitur dengan baik, namun konsumsi memori yang tinggi menjadi hambatan pada perangkat dengan keterbatasan sumber daya.

Selain itu, permasalahan lain yang masih menjadi isu utama adalah ketidakseimbangan dataset (jumlah gambar tiap kelas penyakit tidak merata), yang menyebabkan model bias pada kelas dominan. Beberapa penelitian sebelumnya juga belum mengoptimalkan hyperparameter (optimizer, learning rate, batch size) secara sistematis, sehingga hasil yang diperoleh belum tentu merepresentasikan performa optimal dari arsitektur yang digunakan.

Berdasarkan isu tersebut, penelitian ini berkontribusi dengan:

1. Menerapkan dua arsitektur CNN yang jarang digunakan pada studi kasus ini, yaitu *Inception-V3* dan *EfficientNet-B4*, yang dikenal mampu mengekstraksi fitur kompleks dengan jumlah parameter yang lebih efisien.

2. Menggunakan pendekatan transfer learning untuk mengatasi keterbatasan dataset pada klasifikasi penyakit daun singkong.
3. Melakukan optimasi hyperparameter secara sistematis menggunakan grid search untuk menemukan kombinasi terbaik (optimizer dan learning rate), sehingga menghasilkan model dengan performa lebih baik dan lebih akurat.

Dengan menerapkan *grid search* untuk mengeksplorasi berbagai konfigurasi hyperparameter, penelitian ini bertujuan untuk mengidentifikasi kombinasi terbaik yang dapat meningkatkan akurasi model secara signifikan. Fokus penelitian ini adalah membandingkan performa kedua arsitektur *EfficientNet-B4* dan *Inception-V3* dengan skema *hyperparameter* tuning melalui *grid search*, untuk menemukan kombinasi *hyperparameter* yang optimal. Oleh karena itu, penelitian ini diharapkan dapat memberikan kontribusi yang lebih unggul dalam pengembangan CNN untuk klasifikasi penyakit pada daun singkong, dengan performa yang lebih baik dan lebih akurat.

Sebagian besar penelitian terkait klasifikasi penyakit daun singkong dengan pendekatan deep learning masih menitikberatkan pada peningkatan nilai akurasi secara global sebagai indikator utama keberhasilan model. Pendekatan tersebut memiliki keterbatasan, terutama ketika dataset yang digunakan bersifat tidak seimbang antar kelas penyakit. Pada kondisi ini, nilai akurasi yang tinggi belum tentu mencerminkan kemampuan model dalam mengenali kelas minoritas, yang justru sangat penting dalam konteks deteksi dini penyakit tanaman.

Selain itu, beberapa penelitian sebelumnya belum menyajikan analisis kesalahan klasifikasi secara mendalam melalui confusion matrix, sehingga pola kesalahan model antar kelas penyakit belum teridentifikasi secara jelas. Evaluasi performa model juga umumnya terbatas pada akurasi, tanpa mempertimbangkan metrik lain seperti precision, recall, F1-score, dan Area Under Curve (AUC) yang lebih representatif untuk menilai kinerja model pada dataset tidak seimbang.

Berdasarkan permasalahan tersebut, penelitian ini difokuskan tidak hanya pada perbandingan performa dua arsitektur transfer learning, yaitu Inception-V3 dan EfficientNet-B4, tetapi juga pada analisis komprehensif terhadap performa model menggunakan berbagai metrik evaluasi serta analisis kesalahan klasifikasi. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dari sisi evaluasi dan analisis model, khususnya dalam memahami kemampuan model dalam mengenali kelas penyakit minoritas pada daun singkong.

1.2 Rumusan Masalah

Berdasarkan uraian latar belakang, maka rumusan masalah dalam penelitian ini adalah:

- a. Bagaimana kinerja arsitektur Inception-V3 dan EfficientNet-B4 dalam melakukan klasifikasi penyakit pada daun singkong?
- b. Bagaimana pengaruh ketidakseimbangan dataset dan augmentasi data terhadap performa model klasifikasi penyakit daun singkong?

- c. Bagaimana hasil evaluasi performa model menggunakan metrik akurasi, presisi, recall, dan F1-score, serta bagaimana optimasi hyperparameter melalui grid search dapat meningkatkan performa model?

1.3 Batasan Masalah

- a. Mengimplementasikan arsitektur CNN *Inception-V3* dan *EfficientNet-B4* dengan variasi *optimizer* dan *Learning Rate* menggunakan teknik *grid search* untuk klasifikasi penyakit pada daun singkong.
- b. Menggunakan dataset penyakit pada daun singkong yang tersedia secara publik, yang mencakup gambar daun dari berbagai varietas dan kondisi, sebagai basis data penelitian.
- c. Dari penyakit daun singkong akan dikenali petunjuk dini terkait potensi infeksi atau penyakit. Parameter pengukur kinerja model CNN yang digunakan adalah akurasi, presisi, recall, dan F1- score.

1.4 Tujuan Penelitian

- a. Menganalisis dan membandingkan kinerja arsitektur *Inception-V3* dan *EfficientNet-B4* dalam klasifikasi penyakit pada daun singkong.
- b. Mengkaji pengaruh ketidakseimbangan dataset serta penerapan augmentasi data terhadap performa klasifikasi penyakit daun singkong.
- c. Mengevaluasi hasil klasifikasi dengan menggunakan metrik akurasi, presisi, recall, dan F1-score guna menilai keandalan model.

- d. Menentukan kombinasi hyperparameter (optimizer dan learning rate) terbaik melalui teknik grid search, untuk meningkatkan akurasi dan performa model.

1.5 Manfaat Penelitian

1. Bagi Peneliti

Memperoleh pemahaman dan pengalaman dalam penerapan dan optimasi arsitektur Inception-V3 dan EfficientNet-B4

2. Bagi Bidang Ilmu Pengetahuan dan Penelitian Selanjutnya

Menjadi referensi pengembangan teknologi kecerdasan buatan dalam klasifikasi penyakit tanaman, khususnya pada daun singkong, serta menambah literatur pada bidang Computer Vision dan Deep Learning.

3. Bagi Petani dan Industri Pertanian Singkong

Mendukung deteksi dini penyakit daun singkong sehingga dapat meningkatkan produktivitas dan mengurangi kerugian hasil panen.

BAB 2

TINJAUAN PUSTAKA

2.1 Tinjauan Pustaka

Penelitian yang dilakukan oleh Das et al. pada tahun 2024, yang dipublikasikan di *Journal of Machine Learning Research*, fokus pada penerapan model deep learning untuk klasifikasi penyakit daun dengan menggunakan teknik ensemble. Penelitian ini menunjukkan bahwa kombinasi dari beberapa model deep learning dapat mencapai akurasi tertinggi sebesar 95,8% dengan menggunakan dataset yang terdiri dari berbagai kondisi tanaman. Rekomendasi dari penelitian ini adalah untuk mengeksplorasi penggunaan teknik ensemble dengan model deep learning untuk mencapai performa klasifikasi yang lebih tinggi.

Penelitian yang dilakukan oleh Rajasree R. et al. pada tahun 2023, yang dipublikasikan dalam IEEE, menyajikan hasil signifikan dalam klasifikasi penyakit daun singkong. Model Faster R-CNN yang dioptimalkan mencapai akurasi tinggi sebesar 96% dalam mengidentifikasi penyakit Garis Cassava Brown, menonjolkan efektivitasnya dalam mendeteksi dan mengklasifikasikan penyakit tersebut. Penelitian ini mengadopsi pendekatan dua fase untuk klasifikasi, menggunakan teknik augmentasi data untuk meningkatkan keragaman pelatihan, dan mengevaluasi model dengan metrik akurasi dan matriks kebingungan. Rekomendasi dari penelitian ini adalah untuk terus mengeksplorasi teknik augmentasi data yang lebih canggih dan mempertimbangkan penerapan model pada

kumpulan data yang lebih besar untuk meningkatkan generalisasi dan akurasi lebih lanjut.

Penelitian yang dilakukan oleh Amelia Devi Putri Ariyanto et al. pada tahun 2023, yang dipublikasikan di Jurnal Teknologi Informasi Techno.Com, menganalisis penggunaan pra-proses pada metode Transfer Learning untuk mendeteksi penyakit daun singkong. Mereka menemukan bahwa metode MobileNetV2 tanpa augmentasi memberikan akurasi tertinggi sebesar 98,64% dalam mendeteksi penyakit tanaman singkong. Rekomendasi dari penelitian ini adalah untuk menggunakan jumlah data yang lebih bervariasi dan menggunakan arsitektur yang lebih kompleks dengan parameter yang lebih bervariasi untuk meningkatkan performa model.

Penelitian yang dilakukan oleh Ambrosius dan tim pada tahun 2023, yang dipublikasikan dalam SSRN Electronic Journal, mengembangkan model Convolutional Neural Networks (CNN) untuk diagnosis penyakit daun singkong. Model ini mencapai akurasi prediksi tinggi sebesar 97,28%, dengan presisi 0,9728 dan kerugian validasi di bawah 0,0272, menunjukkan efektivitas dalam mengidentifikasi penyakit daun singkong. Penelitian ini menggunakan dataset yang terdiri dari 22.031 gambar berukuran 800 x 600 piksel, yang mewakili berbagai kelas penyakit daun singkong. Rekomendasi pada penelitian ini adalah untuk meningkatkan ukuran kumpulan data dan mengeksplorasi arsitektur CNN yang lebih kompleks guna mengatasi ketidakseimbangan dalam klasifikasi penyakit.

Penelitian yang dilakukan oleh Andreas Schaefer et al. pada tahun 2023, yang dipublikasikan di IEEE Transactions on Neural Networks and Learning Systems, membahas pengoptimalan model CNN untuk klasifikasi penyakit tanaman dengan menggunakan teknik augmentasi data dan transfer learning. Penelitian ini menunjukkan bahwa model yang menggunakan kombinasi dari berbagai teknik augmentasi data dan transfer learning dapat meningkatkan akurasi hingga 93% pada dataset tanaman. Rekomendasi dari penelitian ini adalah untuk mengintegrasikan teknik augmentasi data lebih lanjut dan melakukan transfer learning untuk meningkatkan akurasi model.

Penelitian yang dilakukan oleh Ardian Eka Nugraha dan rekan pada tahun 2022, yang dipublikasikan dalam eProceedings of Engineering, menggunakan model CNN dari arsitektur VGGNet, yaitu VGG16, untuk mengklasifikasikan penyakit singkong. Meskipun akurasi training mencapai 82,53% dan akurasi validasi mencapai 75%, terdapat tantangan utama terkait ketidakseimbangan jumlah data untuk masing-masing kelas penyakit, yang berdampak pada perbedaan performa model untuk tiap kelas. Rekomendasi yang diberikan adalah untuk meningkatkan jumlah data dan menggunakan arsitektur yang lebih kompleks untuk meningkatkan performa model.

Penelitian yang dilakukan oleh Alex Lianardo dan tim pada tahun 2022, yang dipublikasikan dalam eProceedings of Engineering, menggunakan berbagai arsitektur CNN, termasuk MobileNet V1, V2, dan V3, untuk mengklasifikasikan gejala penyakit pada tanaman singkong. Model terbaik yang dihasilkan menggunakan arsitektur CropNet dengan akurasi mencapai 87,47%. Rekomendasi

dari penelitian ini adalah untuk mempertimbangkan penggunaan arsitektur yang lebih kompleks dan melakukan peningkatan pada parameter seperti *Learning Rate* dan *Batch Size* untuk meningkatkan performa model.

Penelitian yang dilakukan oleh Das. et al. pada tahun 2022, yang dipublikasikan oleh Springer Nature, berkaitan dengan klasifikasi Retinopati Diabetik menggunakan pendekatan CNN. Mereka melakukan pengujian menggunakan 19 arsitektur yang berbeda dan menemukan bahwa EfficientNetB4 merupakan arsitektur yang paling optimal dalam mendeteksi Retinopati Diabetik, dengan akurasi pelatihan mencapai 99,37% dan akurasi validasi mencapai 79,11%. Rekomendasi dari penelitian ini adalah untuk melakukan rekayasa arsitektur yang lebih lanjut, menggunakan dataset yang lebih seimbang, dan melakukan evaluasi menggunakan metrik evaluasi yang signifikan seperti AUROC.


Penelitian yang dilakukan oleh Muhammad Fikri Syahid et al. pada tahun 2022, yang diunggah di Repository UIN Syarif Hidayatullah Jakarta, bertujuan untuk mengklasifikasikan penyakit pada tanaman singkong menggunakan model transfer learning VGG16. Mereka berhasil mencapai akurasi sebesar 70% dengan model yang dilatih menggunakan 5000 dataset gambar dengan augmentasi data. Rekomendasi dari penelitian ini adalah untuk menggunakan arsitektur yang lebih kompleks dan mempertimbangkan penggunaan arsitektur seperti GoogleNet, AlexNet, VGG19, ResNet-50, *Inception-V3*, dan MobileNet untuk meningkatkan performa model.

Penelitian yang dilakukan oleh Umesh Kumar Lilhore et al. pada tahun 2022, yang dipublikasikan oleh MDPI, berfokus pada identifikasi dan klasifikasi penyakit daun singkong menggunakan model CNN yang ditingkatkan (ECNN). Model ECNN menghasilkan akurasi sebesar 99,3% untuk dataset seimbang. Rekomendasi yang diberikan adalah untuk meningkatkan kumpulan data, mempertimbangkan penambahan model CNN dalam bentuk hybrid, dan melakukan analisis eksperimental dengan lebih banyak parameter untuk meningkatkan performa model.

Penelitian yang dilakukan oleh Yiwei Zhong dan rekan pada tahun 2022, yang dipublikasikan oleh MDPI, menggunakan model transformer-embedded ResNet (T-RNet) untuk mengklasifikasikan penyakit daun singkong. Dibandingkan dengan beberapa arsitektur lainnya, metode yang diusulkan mencapai peningkatan kinerja yang signifikan dalam akurasi pengenalan. Rekomendasi dari penelitian ini adalah untuk menggunakan arsitektur yang lebih kompleks dengan parameter yang lebih bervariasi untuk penelitian selanjutnya.

Penelitian yang dilakukan oleh Alina Maryum dan kolega pada tahun 2021, yang dipublikasikan oleh IEEE, fokus pada klasifikasi penyakit daun singkong menggunakan model *EfficientNet-B4* dan U-Net untuk segmentasi. Hasil evaluasi menunjukkan akurasi yang baik, dengan akurasi mencapai 81,43% dan 89,09% pada data validasi untuk dataset asli dan tersegmentasi, secara berturut-turut. Rekomendasi dari penelitian ini adalah untuk menggunakan arsitektur yang lebih kompleks dengan parameter yang lebih bervariasi untuk penelitian selanjutnya.

Terakhir, penelitian yang dilakukan oleh Patike Kiran Rao pada tahun 2021 menggunakan model Separable Convolutions UNet untuk klasifikasi penyakit daun singkong. Model ini menunjukkan akurasi 83,9% untuk diagnosis kesehatan daun dan 61,6% untuk deteksi penyakit. Rekomendasi penelitian ini juga menyarankan penggunaan arsitektur yang lebih kompleks dengan parameter yang lebih bervariasi untuk penelitian mendatang.



2.2 Keaslian Penelitian

tabel 2. 1 Penerapan *Transfer Learning* Dengan *Inception-V3* Dan *EfficientNet-B4* pada Studi Kasus Klasifikasi Penyakit Daun Singkong

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Deep Learning for Plant Disease Detection and Classification: A Systematic Analysis and Review [28]	Pranjit Kumar Das, Subarna Sarker Rupa, dan Mohammed Khalid Hossain 2024	Menggunakan teknik ensemble deep learning untuk klasifikasi penyakit daun.	Kombinasi model mencapai akurasi 95,8%.	Eksplorasi teknik ensemble dengan model deep learning lebih lanjut.	Penelitian ini fokus pada teknik ensemble, sedangkan penelitian ini menggunakan InceptionNet V3 dan EfficientNet-B4 dengan grid search.
2	Implementasi Sistem Pendeteksi Penyakit Pada Daun Singkong Dan Daun Cabai Berbasis Machine Learning [7]	Karel Chavez H dan Luki Hernando, Jurnal Quacom, 2023	Tujuan dari penelitian ini adalah untuk mengembangkan sistem pendeteksi penyakit pada daun singkong dan daun cabai berbasis Deep Learning menggunakan Convolutional	Karena keterbatasan jumlah dataset yang tersedia, penulis menambahkan proses ekstraksi fitur pada citra yang akan diproses. Dengan merubah citra dari format RGB menjadi grayscale, penulis berhasil mempertajam citra	Beberapa kelemahan yang dapat diidentifikasi dari penelitian ini adalah keterbatasan dataset yang digunakan, penggunaan citra grayscale yang mungkin mengurangi informasi warna yang penting, serta ada ruang	Penelitian ini menggunakan arsitektur CNN umum, sementara penelitian ini membandingkan InceptionNet V3 dan EfficientNet-B4 yang lebih spesifik dan melakukan <i>grid search</i> untuk optimasi.

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			Neural Network (CNN).	<p>untuk mempermudah proses ekstraksi. Penggunaan Algoritma CNN dan softmax digunakan untuk mendapatkan hasil yang lebih intuitif dan memudahkan interpretasi probabilitas pada tabel yang dihasilkan. Model yang dilatih dalam penelitian ini memiliki total 16.386 parameter. Hasil pengujian menunjukkan nilai loss sebesar 0.2632, yang dianggap rendah dan baik untuk model ini. Akurasi training mencapai 87.50%, sementara akurasi testing mencapai 82.50%. Proses training dihentikan setelah mencapai 50 epoch.</p>	<p>untuk peningkatan hasil akurasi model. Disarankan untuk memperluas dataset, mempertimbangkan penggunaan citra RGB, dan melakukan evaluasi lebih lanjut terhadap arsitektur model serta proses training untuk meningkatkan performa dan reliabilitas hasil.</p>	

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
3	Cassava Leaf Disease Classification using Optimized Faster R-CNN Model [29]	Rajasree R. et al., IEEE, 2023	Klasifikasi penyakit daun singkong menggunakan Faster R-CNN yang dioptimalkan.	Akurasi tinggi 96% dalam mendeteksi penyakit Garis Cassava Brown.	Eksplorasi augmentasi data yang lebih canggih dan dataset yang lebih besar.	Penelitian ini menggunakan Faster R-CNN dengan augmentasi data, sementara penelitian ini menggunakan InceptionNet V3 dan EfficientNet-B4 dengan optimasi hyperparameter.
	A Deep Learning Approach for Cassava Leaf Disease Diagnosis [30]	Ambrosius et al., SSRN Electronic Journal, 2023	Mengembangkan model CNN untuk diagnosis penyakit daun singkong dengan dataset 22.031 gambar berukuran 800x600.	Model mencapai akurasi 97,28% dengan presisi 0,9728 dan kerugian validasi di bawah 0,0272.	Meningkatkan ukuran dataset dan mengeksplorasi arsitektur CNN yang lebih kompleks.	Penelitian ini menggunakan dataset besar dengan CNN dasar, sedangkan penelitian ini fokus pada InceptionNet V3 dan EfficientNet-B4 dengan grid
	Optimization of CNN for Plant Disease Classification [31]	Andreas Schaefer et al., IEEE Transactions on Neural Networks, 2023	Optimasi model CNN untuk klasifikasi penyakit tanaman dengan teknik augmentasi data dan transfer learning.	Kombinasi augmentasi data dan transfer learning meningkatkan akurasi hingga 93%.	Integrasi lebih lanjut teknik augmentasi data dan transfer learning untuk akurasi yang lebih baik.	Penelitian ini fokus pada augmentasi data dan transfer learning, sementara penelitian ini menggunakan optimasi grid search untuk arsitektur yang lebih canggih.
4	Analisis Penggunaan Pra-Proses	Amelia Devi Putri Ariyanto, dkk, Jurnal	Pada penelitian ini dilakukan klasifikasi tanaman singkong	Penggunaan beberapa metode tersebut bertujuan untuk	Penelitian ini memberikan rekomendasi untuk	Penelitian ini menggunakan pra-proses dan transfer learning, sedangkan penelitian ini fokus pada

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	Pada Metode Transfer Learning untuk Mendeteksi Penyakit Daun Singkong [1]	Teknologi Informasi Tech no.Com, 2023	dengan menggunakan beberapa tahap pra-proses yaitu pra-proses dengan augmentasi, tanpa augmentasi dan pra-proses dengan rotasi, pada beberapa metode <i>transfer learning</i> seperti ResNet50 dan MobileNetV2.	mencari metode mana yang memiliki hasil akurasi tertinggi. Penelitian menunjukkan bahwa MobileNetV2 tanpa augmentasi memberikan akurasi tertinggi sebesar 98.64% dalam mendeteksi penyakit tanaman singkong	menggunakan jumlah data yang lebih bervariasi dan menggunakan arsitektur yang lebih kompleks dengan parameter yang lebih bervariasi.	arsitektur CNN spesifik dan optimasi <i>hyperparameter</i> melalui <i>grid search</i> .
5	Klasifikasi Penyakit Pada Tanaman Singkong Menggunakan Arsitektur VGGNET Berbasis Deep Learning [8]	Ardian Eka Nugraha, dkk. eProceedings of Engineering, 2022	Penulis menggunakan salah satu model CNN dari arsitektur VGGNet yaitu VGG16 untuk mengklasifikasikan penyakit singkong	Model dilatih dengan dataset berupa citra RGB dengan ukuran 224×224 pixel yang dibagi menjadi 5 kelas (CMD, CGM, CBB, CBSD, dan daun sehat) dengan jumlah sebanyak 9430 citra. Proses pelatihan melibatkan	Meskipun nilai akurasinya tidak terlalu besar, namun performa model dari segi pelatihan dan validasi tidak jauh berbeda sehingga model tidak terlalu mengalami <i>Overfitting</i> . Dari segi presisi, recall, dan F1-score, model	Penelitian ini menggunakan VGG16 dan fokus pada dataset RGB, sedangkan penelitian ini menggunakan InceptionNet V3 dan <i>EfficientNet-B4</i> yang merupakan arsitektur berbeda dan mengoptimalkan <i>hyperparameter</i> melalui <i>grid search</i> .

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				<p><i>hyperparameter Batch Size, optimizer, dan Learning Rate</i> yang divariasikan. Hasil pengujian terbaik adalah model dengan <i>Batch Size 32, optimizer SGD, dan Learning Rate 0,001</i> dengan akurasi training sebesar 82,53% dan akurasi validation sebesar 75%.</p>	<p>mendapatkan performa yang berbeda tiap kelas. Masalah utama yang dapat menyebabkan hal tersebut adalah tidak seimbangnya jumlah data untuk masing-masing kelas.</p>	
6	<p>Klasifikasi Gejala Penyakit Daun Pada Tanaman Singkong Berbasis Vision Menggunakan Metode CNN Dengan Arsitektur Mobilenet</p>	<p>Alex Lianardo, dkk, eProceedings of Engineering, 2022</p>	<p>Penulis menggunakan pengolah citra data berbasis algoritma convolution neural network (CNN) di mana merupakan salah satu metode dari deep learning untuk mengklasifikasi gejala penyakit pada</p>	<p>Penulis membandingkan kinerja dari arsitektur CNN yaitu MobileNet V1, MobileNet V2, MobileNet V3, dan CropNet. Terdapat 5656 citra data dengan format JPG yang didapatkan dari situs web www.kaggle.com, yang telah</p>	<p>Tidak disebutkan kekurangan secara mendetail, namun arsitektur dan <i>hyperparameter</i> yang digunakan bisa ditingkatkan lebih lanjut.</p>	<p>Penelitian ini membandingkan berbagai arsitektur MobileNet dan memberikan hasil terbaik dengan CropNet. Penelitian ini berbeda karena fokus pada InceptionNet V3 dan <i>EfficientNet-B4</i> dengan optimasi <i>hyperparameter</i> menggunakan <i>grid search</i>.</p>

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			tanaman singkong melalui citra data daun singkong	diklasifikasikan sebagai lima kelas yaitu CBSD, CMD, CBB, CGM dan healthy (daun sehat). Hasil terbaik yang didapatkan pada Tugas Akhir ini menggunakan arsitektur CropNet dengan <i>hyperparameter</i> berupa <i>optimizer</i> Adam, <i>Learning Rate</i> 0.001, dan <i>Batch Size</i> 32. Hasil yang diperoleh ialah akurasi mencapai 87.47%, presisi sebesar 87%, recall sebesar 82%, dan F1-Score sebesar 84.2%.		
7	Detection of Diabetic Retinopathy using Convolutional Neural Networks for	Das., dkk, Springer Nature, 2022	Pada penelitian tersebut, dilakukan klasifikasi DR menggunakan pendekatan CNN dengan menggunakan 19	Setelah dilakukan pengujian dengan menggunakan dataset gambar fundus EyePACS Kaggle, ditemukan bahwa ResNet50 menunjukkan	Model yang diusulkan akan diperluas melalui rekayasa arsitektur, dan menggunakan dataset gambar fundus yang seimbang dan melakukan perhitungan	Penelitian yang akan dilakukan berbeda karena penelitian ini akan menggunakan dataset penyakit daun singkong.

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	Feature Extraction and Classification (DRFEC) [32]		arsitektur yang berbeda yaitu VGG-19, VGG-16, Xception, InceptionV3, InceptionResNetV2, MobileNet, MobileNetV2, EfficientNet B0-B7, DenseNet121, DenseNet169, DenseNet201, ResNet50, ResNet50V2, ResNet101, ResNet101V2, ResNet152, ResNet152V2, NASNetLarge, dan NASNetMobile.	<i>Overfitting</i> tertinggi dibandingkan dengan Inception V3 yang menunjukkan <i>Overfitting</i> terendah. EfficientNetB4 menjadi algoritma DL yang paling optimal, efisien, dan andal dalam mendeteksi DR, diikuti oleh InceptionResNetV2, NasNetLarge, dan DenseNet169. EfficientNetB4 mencapai akurasi pelatihan tertinggi sebesar 99,37% dan akurasi validasi tertinggi sebesar 79,11%. Sementara DenseNet201 mencapai akurasi pelatihan tertinggi 99,58% dan akurasi validasi 76,80% yang lebih rendah	metrik evaluasi yang signifikan seperti AUROC (<i>area Under the Receiver Operating Characteristic Curve</i>).	

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				<p>daripada empat model terbaik. Oleh karena itu, EfficientNetB4 menjadi arsitektur CNN yang paling baik untuk digunakan dalam klasifikasi DR.</p>		
8	Implementasi deep learning vgg16 dengan transfer learning pada deteksi penyakit tanaman singkong [33]	Muhammad Fikri Syahid, dkk, Repository UIN Syarif Hidayatullah Jakarta, 2022	<p>Penelitian ini bertujuan untuk membuat model deep learning yang dapat mengklasifikasikan penyakit pada tanaman singkong.</p>	<p>Penelitian ini menggunakan 5000 dataset gambar dengan augmentasi data untuk melatih model deep learning yang akan digunakan untuk klasifikasi penyakit tanaman singkong. Model terbaik yang dihasilkan penelitian ini adalah model VGG16 transfer learning dengan <i>Learning Rate</i> 0.00001 pada fine-tuning dan dropout dengan rate 50% yang berhasil mengklasifikasikan</p>	<p>Penelitian ini memberikan rekomendasi untuk menggunakan jumlah data yang lebih bervariasi dan menggunakan arsitektur yang lebih kompleks dengan parameter yang lebih bervariasi, seperti GoogleNet, AlexNet, VGG19, ResNet-50, <i>Inception-V3</i>, dan MobileNet</p>	<p>Penelitian ini menggunakan VGG16 dengan fine-tuning dan dropout untuk transfer learning, sedangkan penelitian ini fokus pada arsitektur InceptionNet V3 dan <i>EfficientNet-B4</i> dengan metode <i>grid search</i> untuk optimasi hyperparameter.</p>

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				penyakit pada tanaman singkong dengan akurasi 70%.		
9	Cassava Leaf Disease Classification using Deep Neural Networks [34]	Alina Maryum dkk. IEEE, 2021	Penelitian ini bertujuan untuk membuat model deep learning yang dapat mengklasifikasikan penyakit pada tanaman singkong.	Penelitian ini menggunakan dataset dari kompetisi Kaggle tahun 2020 yang terdiri dari 21.397 gambar daun tanaman singkong yang dibagi ke dalam 5 kelas: Hawar Bakteri Singkong, Penyakit Goresan Singkong Coklat, Bercak Hijau Singkong, Penyakit Mosaik Singkong, dan Daun Sehat. Metode yang digunakan adalah pelatihan model <i>EfficientNet-B4</i> menggunakan pendekatan transfer learning. Untuk menghilangkan gangguan latar	Penelitian ini memberikan rekomendasi untuk menggunakan arsitektur yang lebih kompleks dengan parameter yang lebih bervariasi.	enelitian ini menggunakan <i>EfficientNet-B4</i> dan U-Net untuk segmentasi, sedangkan penelitian ini fokus pada optimasi <i>hyperparameter</i> InceptionNet V3 dan <i>EfficientNet-B4</i> tanpa segmentasi.

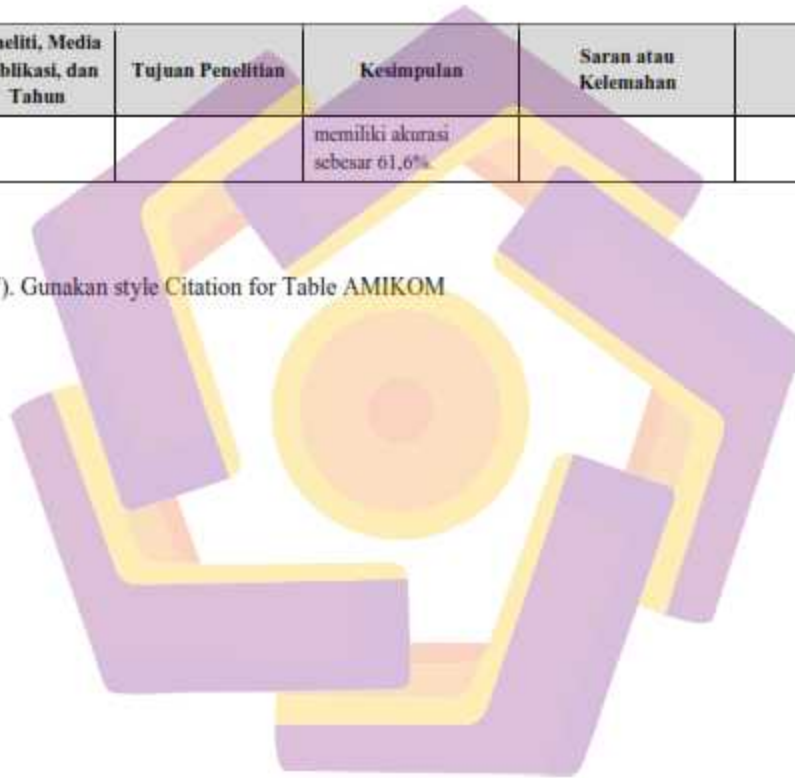
No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				belakang, dilakukan segmentasi dengan menggunakan U-Net untuk mengekstrak hanya daun dari gambar. Hasil evaluasi menunjukkan performa yang baik, dengan akurasi mencapai 81,43% dan 89,09% pada data validasi untuk dataset asli dan tersegmentasi, secara berturut-turut.		
10	Enhanced Convolutional Neural Network Model for Cassava Leaf Disease Identification and Classification [35].	Umesh Kumar Lilhore, dkk, MDPI, 2022	Penelitian ini menyediakan strategi pembelajaran komprehensif untuk identifikasi penyakit daun singkong secara real-time berdasarkan pada model CNN yang	Analisis eksperimental dilakukan atas dataset gambar singkong online yang berisi 6256 gambar daun singkong dengan lima kelas penyakit. Kelas dataset. Klasifikasi ECNN yang diusulkan secara signifikan lebih unggul dan mencapai akurasi	Di masa depan, peneliti menyarankan untuk meningkatkan penelitian saat ini dalam berbagai aspek: (a) kumpulan data dapat ditingkatkan dalam hal ukuran data dan lebih banyak kelas penyakit; (b) model ECNN dapat ditingkatkan dengan	Penelitian ini menggunakan model CNN yang ditingkatkan dengan akurasi sangat tinggi, sedangkan penelitian ini fokus pada arsitektur InceptionNet V3 dan <i>EfficientNet-B4</i> dengan optimasi hyperparameter.

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			ditingkatkan (ECNN).	99,3% untuk dataset seimbang. Temuan uji membuktikan bahwa penerapan database gambar yang seimbang meningkatkan kinerja klasifikasi.	menambahkan lebih banyak model CNN dalam bentuk hybrid; (c) analisis eksperimental dapat dilakukan dalam lingkungan waktu nyata dengan lebih banyak parameter pengukuran kinerja.	
11	Classification of Cassava Leaf Disease Based on a Non-Balanced Dataset Using Transformer-Embedded ResNet [36]	Yiwei Zhong, dkk, MDPI, 2022	Penelitian ini bertujuan untuk membuat model deep learning yang dapat mengklasifikasikan penyakit pada tanaman singkong dengan metode model transformer-embedded ResNet (T-RNet).	Dibandingkan dengan model Xception, VGG16, Inception-V3, ResNet-50, dan DenseNet121, metode yang diusulkan mencapai peningkatan kinerja sebesar 3,05%, 2,62%, 3,13%, 2,12%, dan 2,62% dalam akurasi pengenalan, secara berturut-turut. Sementara itu, peta fitur yang diekstraksi divisualisasikan dan	Penelitian ini memberikan rekomendasi untuk menggunakan arsitektur yang lebih kompleks dengan parameter yang lebih bervariasi	Penelitian ini menggunakan citra grayscale dan CNN umum, sedangkan penelitian ini menggunakan arsitektur CNN yang lebih kompleks InceptionNet V3 dan EfficientNet-B4 dan metode grid search untuk optimasi hyperparameter menggunakan grid search

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				dianalisis dengan gradient-weighted class activation map (Grad_CAM) dan 2D T-SNE, yang memberikan interpretabilitas untuk hasil klasifikasi akhir.		
12	Cassava Leaf Disease Classification using Separable Convolutions UNet [37]	Patike Kiran Rao, Patike Kiran Rao, 2021	Penelitian ini bertujuan untuk membuat model deep learning yang dapat mengklasifikasikan penyakit pada tanaman singkong dengan metode model UNet	Kami menggunakan metode validasi silang 5-kali lipat untuk menguji dua model yang dikembangkan: satu untuk mendiagnosis keadaan kesehatan daun dan yang lainnya untuk mendeteksi penyakit pada daun. Hasilnya menunjukkan bahwa model untuk diagnosis kesehatan memiliki akurasi sebesar 83,9%, sementara model untuk deteksi penyakit	Penelitian ini memberikan rekomendasi untuk menggunakan arsitektur yang lebih kompleks dengan parameter yang lebih bervariasi	Penelitian ini menggunakan model UNet dengan convolutions terpisah, sedangkan penelitian ini fokus pada arsitektur CNN dengan optimasi <i>hyperparameter</i> melalui <i>grid search</i> .

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				memiliki akurasi sebesar 61,6%		

Source: Author (2007). Gunakan style Citation for Table AMIKOM



2.3 Landasan Teori

2.3.1 Daun Singkong

Tanaman daun singkong, atau singkong (*Manihot esculenta*), memiliki peran yang sangat penting dalam pertanian di berbagai daerah tropis dan subtropis, terutama di Asia, Afrika, dan Amerika Latin [13]. Singkong tidak hanya menjadi sumber pangan vital melalui umbinya yang dapat diolah menjadi berbagai produk makanan, tetapi juga melalui daunnya yang digunakan sebagai pakan ternak atau bahan baku makanan [14]. Kandungan nutrisi yang tinggi dalam daun singkong, seperti protein, serat, dan energi, juga menjadikannya bermanfaat bagi kesehatan manusia. Selain itu, budidaya singkong juga memberikan kontribusi besar dalam perekonomian petani di daerah pedesaan, serta menawarkan peluang bisnis yang menjanjikan melalui pengolahan produk singkong.

Pentingnya menjaga kesehatan tanaman daun singkong sangatlah besar untuk memastikan produktivitas yang tinggi dan kualitas produk yang optimal. Tanaman yang sehat cenderung memiliki pertumbuhan yang baik dan lebih tahan terhadap serangan hama dan penyakit, yang dapat dicapai melalui praktik budidaya yang bijaksana. Selain itu, menjaga kesehatan tanaman singkong juga memiliki peran kunci dalam mendukung keberlanjutan produksi pangan, menjaga kelestarian lingkungan, serta mendukung perekonomian lokal. Oleh karena itu, upaya untuk menjaga kesehatan tanaman daun singkong bukan hanya penting bagi petani dan perekonomian, tetapi juga memiliki dampak yang signifikan bagi kesejahteraan manusia dan lingkungan secara keseluruhan.

Tanaman daun singkong rentan terhadap berbagai penyakit yang dapat mengganggu pertumbuhannya dan mengurangi hasil panen [7]. Beberapa penyakit umum pada tanaman singkong meliputi mosaik singkong, antraknosa, cercospora leaf spot, uji kuning, bercak daun, mildiu, dan busuk akar. Identifikasi penyakit dengan tepat sangatlah penting untuk pengendalian yang efektif, mengingat setiap penyakit memiliki gejala yang berbeda dan memerlukan pendekatan yang sesuai dalam penanganannya. Proses identifikasi sering kali membutuhkan waktu yang lama, biaya yang besar, dan terkadang terbatasnya akses terhadap laboratorium. Oleh karena itu, pengelolaan kesehatan tanaman singkong dengan baik menjadi krusial untuk meminimalkan risiko terkena penyakit dan menjaga kualitas hasil panen, yang pada akhirnya akan berdampak langsung pada nilai jual tanaman singkong.

Berdasarkan tinjauan terhadap beberapa penelitian terdahulu, dapat diidentifikasi beberapa keterbatasan yang masih menjadi celah penelitian, antara lain:

1. Sebagian besar penelitian hanya menggunakan metrik akurasi sebagai tolok ukur utama kinerja model, sehingga performa model pada kelas minoritas belum tergambarkan secara utuh.
2. Analisis kesalahan klasifikasi melalui confusion matrix masih jarang dilakukan, padahal analisis tersebut penting untuk mengetahui pasangan kelas penyakit yang sering tertukar.
3. Evaluasi performa model menggunakan metrik AUC untuk kasus klasifikasi multi-kelas masih sangat terbatas.

4. Beberapa penelitian belum membahas secara eksplisit dampak ketidakseimbangan dataset terhadap nilai precision dan recall pada masing-masing kelas penyakit.

Berdasarkan keterbatasan tersebut, penelitian ini menempatkan fokus pada evaluasi model yang lebih komprehensif dan analitis, bukan semata-mata pada pencapaian nilai akurasi tertinggi.

2.3.2 *Convolution Neural Network (CNN)*

CNN adalah jenis desain jaringan saraf tiruan yang biasa digunakan dalam pemrosesan gambar, citra, dan identifikasi pola [13]. CNN menggunakan lapisan lanjutan konvolusional, penyatuan, dan terhubung penuh yang dapat mengekstraksi dan memproses informasi penting dari data masukan untuk menghasilkan keluaran [15]. CNN melakukan operasi konvolusi pada citra masukan dengan banyak kernel pada lapisan konvolusional untuk mengekstrak informasi visual dari citra. Temuan convolutional layer kemudian diproses dengan *layer pooling* untuk mengurangi dimensi gambar dan menghilangkan informasi asing. Hasil dari pooling layer kemudian diteruskan ke *fully connected layer* untuk menghasilkan output.

CNN dimaksudkan untuk menemukan karakteristik spasial, seperti tepi, sudut, tekstur, dan struktur yang lebih abstrak, yang paling baik mencirikan kelas atau kuantitas target. CNN telah diterapkan di berbagai aplikasi dan menghasilkan hasil yang sangat baik dalam pemrosesan video, pengenalan objek, klasifikasi dan segmentasi gambar, pemrosesan bahasa alami, pengenalan ucapan, dan banyak bidang lainnya. Berbagai teknik inovatif untuk meningkatkan kinerja CNN sudah pernah diselidiki, termasuk penggunaan fungsi aktivasi alternatif, *regularisation*,

pengoptimalan parameter, dan kemajuan arsitektur [16]. Inovasi arsitektur juga berkontribusi terhadap peningkatan besar dalam kapasitas CNN, berkat fokus pada pemanfaatan saluran dan informasi spasial, serta kedalaman arsitektur dan pemrosesan *multi-lane* [17].

2.3.3 Machine Learning

Pembelajaran mendalam (deep learning), dimana pendekatan ini didasarkan pada pembelajaran mesin (machine learning) dan visi komputer (computer vision) untuk membangun pengklasifikasian penyakit dengan hanya menggunakan citra daun sebagai masukannya [3]. Hasil dari proses learning didapatkan model CNN dengan akurasi 100% dan loss sebesar 0,012. Pada proses pengujian model CNN yang menggunakan 45 sampel citra buah didapatkan akurasi sebesar 91,42%. Sehingga dapat disimpulkan bahwa metode CNN yang dirancang pada penelitian ini dapat mengklasifikasi citra dengan baik [4]. Sebuah citra yang merepresentasikan informasi visual dari sebuah objek yang dapat didefinisikan sebagai sebuah fungsi 2 dimensi $f(x,y)$, di mana x dan y adalah koordinat spasial dan f merupakan besaran pada setiap pasang koordinat (x,y) disebut intensitas atau tingkat/derajat keabuan, jika semua x,y dan f adalah berhingga dan dalam jumlah diskrit maka citra tersebut disebut sebagai citra digital[5]. Algoritma Convolutional Neural Network (CNN) digunakan untuk klasifikasi jenis penyakit tanaman singkong, yang termasuk dalam bagian metode Deep Learning yang memiliki kemampuan baik dalam mengenali dan mengklasifikasi sebuah objek citra digital[6]

2.3.4 Transfer Learning

Metode transfer learning ini menggunakan model yang telah dilatih sebelumnya atau disebut pre-trained model yang lalu akan dilatih kembali menggunakan dataset yang berbeda. Dasar dari metode transfer learning ini yaitu domain adaptation. Domain adaptation adalah proses mengadaptasi satu atau lebih domain sumber untuk mengambil informasi yang bertujuan untuk meningkatkan performa dari target yang dilatih [11]. Transfer learning umumnya digunakan saat adanya keterbatasan data yang digunakan. Hal ini bisa terjadi karena berbagai kemungkinan seperti data yang diambil tidak mencukupi, ataupun data yang ingin digunakan tidak bisa diakses.

2.3.5 Grid Search

Grid search merupakan metode pencarian hiperparameter yang digunakan untuk mengoptimalkan kinerja model [18]. Dalam pengembangan model deep learning, beberapa parameter seperti *Learning Rate*, *Batch Size*, jumlah layer, dan jumlah neuron dalam setiap layer memiliki pengaruh yang signifikan terhadap kinerja model. Namun, menentukan kombinasi terbaik dari parameter-parameter tersebut sering kali merupakan tantangan besar, terutama ketika jumlahnya banyak dan saling memengaruhi.

Grid search menawarkan solusi untuk tantangan ini dengan cara melakukan eksplorasi sistematis terhadap berbagai kombinasi parameter yang mungkin. Pada dasarnya, *Grid search* akan membuat sebuah grid yang berisi semua kemungkinan kombinasi parameter, kemudian menjalankan setiap kombinasi tersebut untuk

mencari konfigurasi yang memberikan hasil terbaik berdasarkan metrik evaluasi yang digunakan, seperti akurasi atau loss [19].

Dalam penerapannya, *Grid search* melakukan pencarian dengan mengeset beberapa nilai berbeda untuk setiap hiperparameter yang akan diuji. Seluruh kombinasi dari nilai-nilai tersebut diuji secara exhaustif, artinya semua kombinasi kemungkinan diuji satu per satu, meskipun mungkin memerlukan waktu dan sumber daya komputasi yang besar. Pada setiap kombinasi, model deep learning dilatih, dan kinerjanya dievaluasi menggunakan data validasi. Akhirnya, kombinasi hiperparameter yang menghasilkan performa terbaik dipilih sebagai hasil dari pencarian *Grid search*.


Namun, kekurangan *Grid search* adalah konsumsi waktu dan sumber daya yang cukup besar. Jumlah kombinasi yang diuji meningkat secara eksponensial seiring dengan bertambahnya parameter dan jumlah nilai yang diujikan [20]. Oleh karena itu, *Grid search* mungkin kurang efisien ketika jumlah parameter yang diuji terlalu banyak atau ketika setiap iterasi membutuhkan waktu pelatihan yang lama.

2.3.6 Inception-V3

Jaringan GoogLeNet merupakan sebuah CNN yang diusulkan oleh Google pada tahun 2014. Jaringan ini menggunakan struktur jaringan Inception, yang berfungsi tidak hanya untuk mengurangi jumlah parameter dalam jaringan, tetapi juga meningkatkan kedalaman jaringan, sehingga banyak digunakan dalam tugas klasifikasi gambar [12]. Jaringan GoogLeNet juga dikenal sebagai jaringan Inception, karena inti dari jaringan ini adalah struktur jaringan Inception. Terdapat

berbagai versi dari jaringan GoogLeNet, termasuk Inception v1 (2014), Inception v2 (2015), *Inception-V3* (2015), Inception-V4 (2016), dan Inception-ResNet (2016) [12].

Inception-V3 adalah struktur jaringan yang dikembangkan oleh Keras dan sebelumnya telah dilatih dengan *dataset* ImageNet [21]. Ukuran gambar *input default* adalah 299×299 dengan tiga saluran. *Inception-V3* menggunakan metode pemisahan kernel konvolusi untuk memecah *volume* integral besar menjadi konvolusi kecil, seperti misalnya membagi konvolusi 3×3 menjadi dua belitan 3×1 dan 1×3 . Dengan cara ini, jumlah parameter dapat dikurangi, kecepatan pelatihan jaringan dapat ditingkatkan, dan fitur spasial dapat diekstraksi lebih efektif. *Inception-V3* juga mengoptimalkan modul Inception dengan menggunakan tiga grid area yang berbeda (35×35 , 17×17 , dan 8×8). Hal ini membantu meningkatkan kinerja jaringan dan mengurangi jumlah parameter yang diperlukan. Sebagai hasilnya, *Inception-V3* menunjukkan kinerja yang lebih baik dibandingkan dengan Inception v1 dan v2 dalam tugas klasifikasi gambar. Berikut adalah struktur jaringan pada *Inception-V3*:



Gambar 2. 1 Struktur Jaringan pada *Inception-V3*


Model ini terdiri dari beberapa lapisan dengan arsitektur yang kompleks dan telah terbukti mampu mencapai akurasi tinggi pada tugas pengenalan objek. Lapisan pertama pada jaringan ini adalah lapisan konvolusi dengan filter berukuran 3×3 untuk melakukan ekstraksi fitur pada gambar. Selanjutnya, dilakukan beberapa operasi konvolusi dengan filter yang berbeda-beda ukurannya pada satu lapisan, dalam sebuah blok yang disebut *Inception module*. *Inception module* terdiri dari beberapa lapisan konvolusi dengan ukuran filter yang berbeda-beda, yaitu 1×1 , 3×3 , dan 5×5 , serta operasi *max pooling*. Setiap lapisan pada *Inception module* bertujuan untuk mengekstraksi fitur dari gambar dengan ukuran yang berbeda-beda, sehingga dapat menghasilkan fitur-fitur yang lebih variatif.

Selanjutnya, dilakukan operasi penggabungan informasi dari beberapa blok *Inception* yang berbeda. Operasi penggabungan ini dilakukan dengan menggunakan lapisan *concatenation*, yaitu menggabungkan *output* dari beberapa blok *Inception* menjadi satu tensor yang besar. Setelah itu, dilakukan lapisan reduksi dimensi dengan menggunakan lapisan *global average pooling*, yang memiliki fungsi untuk mengurangi dimensi dari tensor yang besar menjadi sebuah vektor fitur. Vektor

fitur ini selanjutnya disambungkan ke lapisan *fully connected* yang bertujuan untuk menghasilkan *output* kelas pada tugas pengenalan objek. Jaringan *Inception-V3* memiliki beberapa keunggulan, di antaranya adalah kemampuan untuk menghasilkan fitur-fitur yang lebih variatif, serta kemampuan untuk mengurangi jumlah parameter pada jaringan sehingga dapat mempercepat proses training dan inferensi.

2.3.7 EfficientNetB4

EfficientNet adalah sebuah arsitektur jaringan saraf tiruan (Neural Network) yang dikembangkan untuk tugas-tugas dalam bidang visi komputer, seperti klasifikasi gambar dan deteksi objek. Arsitektur ini diusulkan oleh Mingxing Tan dan Quoc V. Le dari Google Brain pada tahun 2019 [22]. Keunggulan utama dari EfficientNet adalah kemampuannya untuk mencapai kinerja yang tinggi dengan menggunakan jumlah parameter yang lebih sedikit dibandingkan dengan arsitektur sebelumnya. Konsep dasar di balik EfficientNet adalah menggunakan metode skala, kedalaman, dan lebar yang seimbang untuk merancang arsitektur yang efisien. Dalam konteks ini, "skala" mengacu pada faktor skala yang mengatur resolusi gambar input, "kedalaman" mengacu pada kedalaman jaringan atau jumlah lapisan, dan "lebar" mengacu pada lebar setiap lapisan atau jumlah filter di setiap lapisan.



Gambar 2. 2 Struktur Jaringan pada *EfficientNet*

EfficientNet menggunakan pendekatan Compound Scaling untuk menyesuaikan skala, kedalaman, dan lebar secara bersamaan dengan tetap mempertahankan efisiensi komputasinya [23]. Pendekatan ini memungkinkan jaringan untuk mencapai kinerja yang tinggi dengan mempertimbangkan keterbatasan sumber daya komputasi yang tersedia. Selain itu, EfficientNet juga memanfaatkan teknik seperti depthwise separable convolution, squeeze-and-excitation blocks, dan swish activation function untuk meningkatkan kinerja dan efisiensi jaringan [24]. Dengan kombinasi strategi tersebut, EfficientNet telah terbukti menjadi arsitektur yang sangat efektif dan efisien dalam berbagai tugas visi komputer, dan telah menjadi pilihan populer di komunitas penelitian dan industri.

Di satu sisi, Model EfficientNet dibangun berdasarkan metode penskalaan komponen yang sederhana namun sangat efektif [25]. Pendekatan ini memungkinkan untuk memperbesar jaringan saraf tiruan (ConvNet) dasar ke berbagai batasan sumber daya yang berbeda sambil tetap mempertahankan efisiensi

model, sehingga sangat berguna untuk tugas transfer learning. Secara umum, model EfficientNet mencapai akurasi yang lebih tinggi dan efisiensi yang lebih baik dibandingkan dengan jaringan saraf tiruan konvensional yang ada seperti AlexNet, ImageNet, GoogleNet, dan MobileNetV2 [26]. Hal ini menunjukkan bahwa EfficientNet dapat menjadi standar baru untuk tugas-tugas visi komputer di masa depan.

EfficientNet terdiri dari model-model mulai dari B0 hingga B7, yang masing-masing memiliki jumlah parameter yang berbeda antara 5,3 juta hingga 66 juta [27]. Dalam studi ini, peneliti memilih untuk menggunakan EfficientNetB4, yang memiliki sekitar 19 juta parameter. Pemilihan ini didasarkan pada ketersediaan sumber daya dan kesesuaian dengan tujuan studi.

2.3.8 Parameter Pengujian Sistem

Parameter Pengujian Sistem adalah tahap untuk membandingkan hasil yang diperoleh dari implementasi dengan kriteria dan standar yang telah ada untuk mendapatkan angka keberhasilan dari implementasi. Pada penelitian ini, digunakan *Confusion Matrix* sebagai metode validasi model yang telah dibangun. Adapun parameter performansi yang digunakan adalah akurasi, *recall*, *precision*, *F1-Score*, dan *Area Under Curve (AUC)*.

a. Confusion Matrix

Confusion matrix yaitu sebuah tabel yang terdiri atas banyaknya baris data uji yang diprediksi benar dan tidak benar oleh model klasifikasi, tabel ini diperlukan untuk menentukan kinerja suatu model klasifikasi. Berikut adalah tabel *confusion matrix* untuk kelas prediksi dan kelas aktual:

Tabel 2. 2 *Confusion Matrix*

Kategori	Kelas Prediksi (<i>Predicted Class</i>)		
Kelas Aktual (<i>Actual Class</i>)		Ya (+)	Tidak (-)
	Ya (+)	TP	FN
	Tidak (-)	FP	TN

Keterangan Tabel *Confusion matrix*:

1. TP (*True Positif*/Benar Positif)

TP merupakan keadaan ketika kelas prediksi *Yes* dan kelas Aktual *Yes*. Artinya ini merupakan hasil yang benar.

2. FP (*False Positif*/Salah Positif)

FP merupakan keadaan ketika kelas prediksi *Yes* dan kelas Aktual *No*. Artinya ini merupakan hasil yang tidak diharapkan.

3. FN (*False Negatif*/Salah Negatif)

FN merupakan keadaan ketika kelas prediksi *No* dan kelas Aktual *Yes*. Artinya ini merupakan hasil yang melenceng atau meleset dari yang sebenarnya.

4. TN (*True Negatif*/Benar Negatif)

TN merupakan keadaan ketika kelas prediksi *No* dan kelas actual *No*. Artinya ini merupakan tidak adanya hasil yang benar.

b. Akurasi

Akurasi atau *Accuracy* (Q) merupakan tingkat kedekatan antara nilai prediksi yang telah dilakukan dengan nilai yang sebenarnya. Akurasi digunakan untuk melakukan evaluasi agar mengetahui banyaknya jumlah label prediksi yang tepat sesuai dengan label aktual. Akurasi memiliki konsep yaitu semakin besar nilai akurasinya, maka performansi dari klasifikasi yang telah dilakukan akan semakin baik. Persamaan untuk menghitung akurasi dituliskan sebagai berikut:

$$Q = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

c. Recall

Recall atau *Sensitivity* (SE) adalah tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi. Persamaan untuk menghitung *Recall* dituliskan sebagai berikut:

$$SE = \frac{TP}{TP + FN} \quad (2)$$

d. Precision

Precision (PR) adalah tingkat ketepatan antara informasi yang diharapkan oleh pengguna atau *user* dengan jawaban yang dihasilkan oleh sistem yang telah dibangun. Persamaan untuk menghitung *Precision* dituliskan sebagai berikut:

$$PR = \frac{TP}{TP + FP} \quad (3)$$

a. F1-Score

F1-Score adalah perhitungan untuk mengukur performansi dari gabungan nilai *precision* dan *recall*. Persamaan untuk menghitung *F1-Score* dituliskan sebagai berikut:

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

2.3.9 Penyakit Daun Singkong

Tanaman singkong yang terjangkit penyakit dapat menurunkan kualitas singkong itu sendiri. Pendeteksian penyakit pada singkong biasanya dapat terlihat dari perubahan pada bagian tanaman misalnya pada bagian daun dan batang. Daun tanaman singkong yang terjangkit penyakit biasanya menunjukkan tanda – tanda seperti berubahnya warna dan bentuk dari daun yang dapat dilihat secara kasat mata. Diagnosis penyakit pada tanaman singkong yang cepat dan tepat dapat mempermudah proses pencegahan pada penyakit agar tidak merusak tanaman singkong. Beberapa contoh penyakit pada tanaman singkong yang gejalanya masih dapat dilihat secara kasat mata antara lain seperti antraknosa, bercak daun, dan virus daun kering. Fokus dari penelitian ini adalah klasifikasi ketiga penyakit tersebut berdasarkan gejala yang tampak pada daun singkong.

BAB 3 METODE PENELITIAN

3.1 Jenis, Sifat, dan Pendekatan Penelitian

Berikut ini penjelasan mengenai jenis, sifat, dan pendekatan yang digunakan dalam penelitian.

3.1.1. Jenis Penelitian

Penelitian ini menggunakan desain penelitian eksperimen (Experimental Research). Desain penelitian eksperimen adalah metode penelitian yang melibatkan manipulasi variabel independen untuk mengamati efeknya pada variabel dependen, dengan tujuan menentukan hubungan sebab-akibat. Penelitian eksperimen sering dianggap sebagai metode penelitian yang paling kuat dalam mengidentifikasi hubungan kausal karena kontrol yang ketat terhadap variabel-variabel yang terlibat. Desain ini memungkinkan peneliti untuk secara sistematis mengeksplorasi perbedaan performa antara arsitektur CNN *Inception-V3* dan *EfficientNet-B4* setelah optimasi *hyperparameter* melalui *grid search*.

3.1.2. Sifat Penelitian

Sifat penelitian ini adalah **kausal** dan **applied research**. Penelitian ini bertujuan untuk menemukan hubungan sebab-akibat antara pengaturan *hyperparameter* dan performa model dalam klasifikasi penyakit daun singkong. Penelitian ini juga berorientasi pada penerapan praktis, yakni menerapkan teknik deep learning yang telah ada untuk meningkatkan kemampuan deteksi penyakit tanaman. Dengan mengadaptasi teknik dari penelitian sebelumnya, penelitian ini

tidak hanya berfokus pada teori tetapi juga pada aplikasi praktis yang dapat meningkatkan produktivitas dan efisiensi dalam sektor pertanian.

3.1.3. Pendekatan Penelitian

Pendekatan penelitian ini menggunakan pendekatan kuantitatif, karena data yang dikumpulkan berupa angka-angka dan dianalisis menggunakan metode perhitungan matematis untuk memperoleh hasil yang diinginkan. Pendekatan ini memungkinkan peneliti untuk menguji hipotesis secara objektif dan memperoleh kesimpulan berdasarkan data statistik. Selain itu, penelitian ini dilaksanakan sesuai dengan langkah-langkah atau alur yang telah ditentukan oleh peneliti, sehingga proses penelitian dapat terstruktur dengan baik dan hasilnya dapat diulang serta diverifikasi oleh peneliti lain.

3.2 Metode Pengumpulan Data

Data yang digunakan adalah dataset cassava leaf disease yang tersedia di Kaggle. Dataset berupa gambar daun singkong berwarna dengan format .jpg dengan kategori penyakit, yaitu *Cassava Bacterial Blight (CBB)*, *Cassava Brown Streak Disease (CBSD)*, *Cassava Green Mottle (CGM)*, *Cassava Mosaic Disease (CMD)*, dan *Healthy*. Berikut ini merupakan contoh gambar dari setiap label :



Gambar 3. 1 Cassava Bacterial



Gambar 3. 1 Cassava Brown



Gambar 3. 3 Cassava Green



Gambar 3. 4 Cassava Healthy



Gambar 3. 5 Cassava Mosaic

Jumlah total gambar dalam dataset adalah 21.397 gambar, dengan distribusi yang tidak merata. Kelas *Cassava mosaic disease* mendominasi dataset, sementara kelas lainnya memiliki jumlah gambar yang lebih sedikit. Distribusi yang tidak merata ini menimbulkan tantangan dalam pelatihan model karena dapat menyebabkan bias terhadap kelas mayoritas. Tabel persebaran kelas dataset adalah sebagai berikut :



Gambar 3. 2 Distribusi Dataset pada *Training Set*

Untuk menangani masalah ketidakseimbangan ini, dilakukan augmentasi gambar untuk memperkaya variasi data pada kelas minoritas

3.3 Metode Analisis Data

Bagian ini memuat penjelasan secara lengkap dan terinci tentang metode dan alat yang digunakan untuk analisis data.

3.3.1 Alat

a. Perangkat Keras

Perangkat keras yang digunakan dalam penelitian ini adalah sebuah laptop dengan spesifikasi sebagai berikut: prosesor Intel® Core™ i5 3317U, CPU @ 1.70GHz, RAM 8GB, dan SSD berkapasitas 256GB. Laptop ini digunakan untuk melakukan semua tahap pengujian.

b. Perangkat Lunak

1. Bahasa Pemrograman

Python digunakan sebagai bahasa pemrograman utama dalam penelitian ini.

2. Scikit-learn

Scikit-learn digunakan sebagai kerangka kerja (framework) untuk mengolah dataset. Tahap-tahap yang dilakukan meliputi pembersihan data, implementasi algoritma, dan perhitungan validasi model.

3. TensorFlow dan Keras

TensorFlow dan Keras digunakan untuk membangun, melatih, dan mengevaluasi model machine learning dan deep learning. Keras, yang merupakan antarmuka tingkat tinggi dari TensorFlow, mempermudah proses pembangunan dan pelatihan model neural network.

4. Google Colab


Google Colab digunakan sebagai platform untuk menjalankan dokumen dengan format *ipynb* (Jupyter Notebook) menggunakan bahasa pemrograman Python melalui web browser. Google Colab menyediakan sumber daya komputasi tambahan yang diperlukan untuk menjalankan model yang lebih kompleks. Terutama untuk pelatihan model dengan arsitektur CNN yang memerlukan waktu dan daya komputasi yang lebih besar.

3.3.2 Bahan

Dataset penyakit pada daun singkong diambil dari platform Kaggle. Dataset ini mencakup gambar daun singkong dari berbagai varietas dan kondisi. Dataset ini telah dipilih karena keragamannya yang mencakup berbagai kelas penyakit, yang mendukung tujuan penelitian untuk menguji dan membandingkan performa arsitektur CNN dalam konteks klasifikasi yang beragam.

3.4 Alur Penelitian

Penelitian ini bertujuan untuk membandingkan performa arsitektur CNN *Inception-V3* dan *EfficientNet-B4* dalam klasifikasi penyakit daun singkong dengan menggunakan teknik *grid search* untuk mengoptimalkan *hyperparameter* seperti *optimizer* dan *Learning Rate*. Adapun alur penelitian yaitu sebagai berikut :



Gambar 3. 3 Alur Penelitian

3.4.1 Pengumpulan Data Sekunder

Dataset untuk penelitian ini mencakup gambar daun singkong yang terinfeksi berbagai penyakit. Data ini dapat diperoleh dari sumber publik yang tersedia secara online yaitu Kaggle. Data ini dapat diakses melalui link berikut : https://www.kaggle.com/competitions/cassava-leaf-disease-classification/data?select=train_images. Data ini mencakup gambar daun singkong yang telah dikategorikan ke dalam beberapa kelas penyakit. Dataset ini akan menjadi dasar untuk pelatihan dan pengujian model CNN.

3.4.2 Augmentasi Gambar

Augmentasi gambar adalah teknik yang digunakan dalam pemrosesan citra untuk memperbanyak dan memperkaya dataset gambar tanpa harus mengumpulkan gambar tambahan. Teknik ini sangat penting dalam penelitian yang melibatkan model pembelajaran mesin dan pembelajaran mendalam, terutama ketika dataset asli tidak cukup besar atau beragam untuk melatih model dengan baik. Augmentasi gambar membantu dalam meningkatkan performa dan generalisasi model dengan

membuatnya lebih tahan terhadap variasi dalam data, yang sangat relevan untuk klasifikasi gambar yang beragam.

Teknik-teknik augmentasi gambar yang akan dilakukan adalah:

1. Rotasi (Rotation)

Mengubah orientasi gambar pada berbagai sudut untuk membuat model tahan terhadap perubahan rotasi.

2. Pemotongan (Cropping)

Memotong bagian-bagian gambar untuk memperkenalkan variasi dalam ukuran dan posisi objek dalam gambar.

3. Pembalikan (Flipping)

Membalik gambar secara horizontal atau vertikal untuk memberikan variasi orientasi objek.

4. Perubahan Skala (Scaling)

Mengubah ukuran gambar atau objek di dalamnya untuk membuat model lebih tahan terhadap perubahan skala.

5. Translasi (Translation)

Menggeser gambar secara horizontal atau vertikal untuk memperkenalkan variasi dalam posisi objek.

6. Perubahan Pencahayaan (Brightness Adjustment)

Mengubah kecerahan gambar untuk membuat model lebih tahan terhadap variasi pencahayaan.

7. **Shearing**

Menerapkan deformasi geometri pada gambar untuk memperkenalkan variasi dalam bentuk objek.

8. **Penambahan Noise**

Menambahkan noise acak pada gambar untuk membuat model lebih tahan terhadap gangguan atau distorsi.

9. **Blurring**

Menerapkan efek blur pada gambar untuk membuat model lebih tahan terhadap gambar yang tidak fokus.

3.4.3 **Pemrosesan Gambar**

Pemrosesan gambar adalah serangkaian teknik yang digunakan untuk memanipulasi dan menganalisis gambar digital dengan tujuan meningkatkan kualitas gambar, mengekstrak informasi penting, atau mempersiapkan gambar untuk analisis lebih lanjut dalam sistem berbasis kecerdasan buatan. Pemrosesan gambar merupakan langkah penting untuk memastikan bahwa gambar yang digunakan dalam pelatihan model dalam kondisi optimal dan sesuai dengan standar yang diharapkan oleh model.

Teknik-teknik pemrosesan gambar yang akan digunakan adalah:

1. **Pengubahan Ukuran (Resizing)**

Mengubah ukuran gambar agar sesuai dengan dimensi input yang diharapkan oleh model pembelajaran mesin. Misalnya, mengubah ukuran gambar menjadi 224x224 piksel.

2. Normalisasi Piksel

Mengubah nilai piksel gambar ke dalam rentang yang lebih kecil, biasanya 0 hingga 1, dengan cara membagi nilai piksel dengan 255.

3.5 Pembagian Data

Dataset dibagi menjadi data pelatihan dan data pengujian dengan proporsi 80:20%. Pembagian ini dilakukan untuk memastikan bahwa model dapat dilatih dengan data yang cukup dan diuji pada data yang belum pernah dilihat sebelumnya, sehingga dapat memperoleh estimasi yang akurat mengenai performa model pada data yang belum dikenal.

3.6 Pembangunan Model

Setelah pembagian data, langkah selanjutnya adalah pembangunan model menggunakan arsitektur *Inception-V3* dan *EfficientNet-B4*. Kedua arsitektur ini akan digunakan untuk membangun dan melatih model pembelajaran mesin yang dapat mengenali pola dan fitur dari dataset yang telah dibagi. Dalam proses pembangunan model ini, berbagai kombinasi *optimizer* dan *Learning Rate* akan diuji menggunakan teknik *grid search* untuk menemukan konfigurasi terbaik yang menghasilkan kinerja optimal. *Grid search* akan mengeksplorasi berbagai konfigurasi *hyperparameter* untuk menemukan kombinasi yang memberikan performa terbaik, sehingga model yang dihasilkan memiliki kemampuan prediksi yang lebih baik dan dapat diandalkan.

Tabel 3. 1 Parameter Algoritma

No	Parameter	Inception-V3	EfficientNet-B4	Keterangan
1	Optimizer	Adam, RMSprop, SGD	Adam, RMSprop, SGD	Variasi dicoba melalui penyetelan parameter
2	Learning Rate	0.01, 0.001, 0.0001	0.01, 0.001, 0.0001	Rentang penyetelan parameter
3	Batch Size	16, 32, 64	16, 32, 64	Ditentukan pada saat training
4	Epoch	25 – 50	25 – 50	Disesuaikan hingga model konvergen
5	Ukuran Input	299 × 299 × 3	380 × 380 × 3	Sesuai arsitektur bawaan
6	Jumlah Kelas	5 (CMD, CGM, CBB, CBSD, Sehat)	5 (CMD, CGM, CBB, CBSD, Sehat)	Label klasifikasi
7	Augmentasi Data	Rotasi, flipping, scaling, brightness, shearing	Sama	Diterapkan hanya pada data training & validation
8	Dataset Testing	Tanpa augmentasi	Tanpa augmentasi	Digunakan untuk evaluasi akhir

3.7 Evaluasi Model

Evaluasi model merupakan langkah penting dalam pengembangan sistem pembelajaran mesin. Ini memungkinkan kita untuk mengukur kinerja model yang telah dibangun dan memastikan bahwa model tersebut dapat digunakan secara efektif dalam kasus penggunaan yang sesuai. Evaluasi model melibatkan penggunaan metrik evaluasi yang relevan untuk mengevaluasi kinerja model terhadap data pengujian yang belum pernah dilihat sebelumnya. Dalam evaluasi model, akan menggunakan metrik akurasi, recall, presisi, dan F1-Score, yang merupakan metrik penting dalam konteks klasifikasi penyakit daun singkong untuk memastikan model memiliki performa yang baik dan dapat digunakan dalam aplikasi nyata.



BAB 4

HASIL PENELITIAN DAN PEMBAHASAN

Penelitian ini berfokus pada klasifikasi penyakit daun singkong menggunakan model *Inception-V3* dan *EfficientNet-B4* yang dioptimalkan melalui teknik *Transfer Learning*. Penelitian ini terdiri dari beberapa tahapan, mulai dari pengumpulan data, augmentasi gambar, pembangunan model, hingga tuning hyperparameter. Setiap tahap dijelaskan secara rinci sebagai berikut:

4.1 Argumentasi Gambar

Dalam penelitian ini, teknik augmentasi gambar diterapkan untuk memperkaya dataset dan meningkatkan generalisasi model. Proses augmentasi melibatkan beberapa transformasi pada gambar asli untuk menciptakan variasi yang berbeda. Teknik augmentasi yang diterapkan meliputi:

- **Random Flip:** Membalik gambar secara horizontal.
- **Random Rotation:** Merotasi gambar dengan sudut acak hingga 20 derajat.
- **Random Zoom:** Melakukan zoom in/out pada gambar secara acak.
- **Random Contrast:** Mengubah tingkat kontras gambar untuk mensimulasikan kondisi pencahayaan yang berbeda.

4.2 Prapemrosesan Gambar

Pemrosesan data dilakukan melalui dua tahapan yaitu dengan mengubah ukuran gambar menjadi 128x128 *pixel* dan untuk mengubah skala intensitas warna pada gambar yang semula 0 – 255 menjadi hanya 0 – 1.

4.3 Pembagian Data

Dataset total terdiri dari gambar daun singkong yang terbagi dalam 5 kelas penyakit. Data dibagi menjadi tiga bagian yaitu *Data Train* sebesar 80%, *data validation* sebesar 10% dan *data test* sebesar 10%.

4.4 Pembangunan Model

Pada tahap ini, pembangunan model difokuskan pada dua arsitektur deep learning yang digunakan untuk klasifikasi penyakit daun singkong, yaitu *Inception-V3* dan *EfficientNet B4*. Kedua model ini telah dilatih sebelumnya (*pre-trained*) pada dataset *ImageNet*. Transfer learning digunakan dengan memanfaatkan bobot dari model-model tersebut yang sudah dilatih untuk mengenali objek umum dari *ImageNet*, kemudian lapisan-lapisan atas dari masing-masing model disesuaikan dan dilatih kembali khusus untuk tugas klasifikasi penyakit daun singkong. Adapun hasil dari setiap pengujian yaitu sebagai berikut:

4.4.1 Model Inception-V3

Langkah pertama adalah memuat model *Inception-V3* tanpa lapisan akhir dan menambahkan beberapa lapisan tambahan seperti *Global Average Pooling* dan *Dense Layer*.

Pada model ini, *Inception-V3* digunakan sebagai bagian utama dari arsitektur dengan bobot awal yang sudah dilatih pada dataset *ImageNet*, yang memberikan kemampuan dasar pengenalan objek. Lapisan *GlobalAveragePooling2D* diterapkan untuk menggantikan lapisan *fully connected* yang lebih berat, dengan tujuan mengurangi kompleksitas model. Selanjutnya,

lapisan Dense dengan jumlah neuron bervariasi, yaitu 128 atau 256 neuron, disesuaikan berdasarkan hyperparameter yang diuji untuk menemukan konfigurasi terbaik. Untuk mencegah *Overfitting*, Dropout ditambahkan, yang berfungsi membuang sebagian neuron secara acak selama proses pelatihan. Selain itu, *Learning Rate* scheduler digunakan untuk menurunkan *Learning Rate* secara bertahap, sehingga membantu model terhindar dari solusi lokal dan meningkatkan stabilitas pelatihan.

4.4.2 Model EfficientNet-B4

EfficientNet-B4 digunakan sebagai model pre-trained yang diambil dari dataset ImageNet, mirip dengan *Inception-V3*. Transfer learning diterapkan dengan memodifikasi beberapa lapisan akhir agar sesuai dengan tugas klasifikasi penyakit daun singkong.

Pada gambar di atas, model *EfficientNet-B4* digunakan sebagai bagian utama dari arsitektur dengan bobot awal yang sudah dilatih pada dataset ImageNet. Pada arsitektur ini, lapisan Global Average Pooling diterapkan untuk menggantikan lapisan fully connected yang besar dan berat, sehingga mengurangi kompleksitas model. Selanjutnya, lapisan Dense dengan jumlah neuron yang bervariasi, yaitu 128 atau 256 neuron, diuji untuk menemukan kombinasi yang paling optimal. Untuk menghindari *Overfitting*, Dropout ditambahkan dengan tujuan menghapus beberapa neuron secara acak selama pelatihan. Selain itu, *Learning Rate* Scheduler digunakan agar *Learning Rate* dapat disesuaikan secara bertahap selama proses pelatihan, membantu model mencapai konvergensi yang lebih stabil

4.5 Tuning Hyperparameter

Untuk memastikan model berfungsi secara optimal, dilakukan tuning hyperparameter melalui uji coba berbagai kombinasi *Batch Size*, *Learning Rate*, dan *Dense Units*. Hyperparameter yang diuji adalah sebagai berikut:

- *Batch Size*: 16, 32
- *Learning Rate*: 0.0001
- *Dense Units*: 128, 256

Kombinasi ini diuji secara manual dengan menggunakan grid search, di mana setiap kombinasi diuji pada dataset yang telah diaugmentasi.

4.6 Pelatihan dan Evaluasi

Model dilatih dengan menggunakan *early stopping*, yang secara otomatis menghentikan pelatihan jika model tidak menunjukkan peningkatan performa pada data validasi setelah beberapa epoch. Hal ini penting untuk mencegah *Overfitting*, di mana model terlalu menyesuaikan dengan data pelatihan tetapi gagal menggeneralisasi data baru.

Evaluasi model dilakukan dengan menggunakan metrik-metrik berikut:

- Akurasi Pelatihan (*Training Accuracy*)
- Akurasi Validasi (*Validation Accuracy*)
- Loss Pelatihan (*Training Loss*)
- Loss Validasi (*Validation Loss*)

4.7 Hasil Penelitian

Setelah semua kombinasi hyperparameter diuji dengan *Learning Rate* 0.0001, adapun hasil pelatihan dan validasi dapat dilihat pada tabel berikut:

Tabel 4. 1 Hasil Penelitian

Model	Learning Rate	Dense Units	Val Acc	Val Loss	Train Acc	Train Loss
Inception-V3	16	128	0.7043	0.8207	0.6587	0.9553
		256	0.7428	0.6935	0.7067	0.8433
	32	128	0.6875	0.9156	0.6927	0.9570
		256	0.7396	0.7144	0.7135	0.8518
EfficientNet-B4	16	128	0.6514	1.1190	0.6587	1.1513
		256	0.6587	1.0951	0.6514	1.1471
	32	128	0.6719	1.0812	0.6562	1.1476
		256	0.6979	1.0289	0.6771	1.1034

Dari tabel di atas, dapat dilihat performa dari masing-masing kombinasi hyperparameter yang diuji untuk kedua model. Kombinasi **hyperparameter terbaik** untuk *Inception-V3* adalah *Batch Size* 16, *Learning Rate* 0.0001, dan *Dense Units* 256, yang menghasilkan *Validation Accuracy* sebesar 74.28% dan *Validation Loss* sebesar 0.6935. Sedangkan untuk *EfficientNet B4*, kombinasi terbaik juga ditemukan dengan *Batch Size* 32, *Learning Rate* 0.0001, dan *Dense Units* 256, dengan *Validation Accuracy* sebesar 69.79% dan *Validation Loss* sebesar 1.0289.

4.7.1. Kinerja Model

Hasil dari pengujian menunjukkan bahwa *Inception-V3* berhasil mencapai performa yang lebih baik dibandingkan dengan *EfficientNet-B4* dalam klasifikasi penyakit daun singkong. *Inception-V3* memperoleh *Validation Accuracy* sebesar 74.28%, lebih tinggi dibandingkan *EfficientNet-B4* yang mencatatkan 69.79%. Selain itu, *Inception-V3* juga memiliki *Validation Loss* yang lebih rendah (0.6935) dibandingkan dengan *EfficientNet-B4* yang mencapai 1.0289. Hal ini menunjukkan bahwa *Inception-V3* lebih efisien dalam menangani kompleksitas data dan mampu menggeneralisasi lebih baik pada data validasi.

4.7.2. Pengaruh Hyperparameter

Pengujian berbagai kombinasi hyperparameter mengungkapkan bahwa :

- **Batch Size:** Hasil menunjukkan bahwa *Batch Size* yang lebih kecil (16) memberikan akurasi validasi yang lebih baik dibandingkan dengan *Batch Size* yang lebih besar (32). Hal ini mungkin terjadi karena *Batch Size* yang lebih kecil memungkinkan model untuk lebih sering memperbarui bobotnya. Dengan demikian, model dapat mempelajari lebih banyak variasi data dalam setiap iterasi, yang meningkatkan kemampuan model dalam menangkap pola yang ada pada dataset.
- **Dense Units:** Penggunaan jumlah neuron yang lebih besar pada dense layer (256) menunjukkan hasil yang lebih baik dibandingkan dengan jumlah neuron yang lebih kecil (128). Dengan lebih banyak neuron, model memiliki kapasitas yang lebih besar untuk menangkap pola yang lebih kompleks dari gambar. Ini penting terutama untuk tugas klasifikasi yang sulit seperti klasifikasi penyakit daun singkong, di mana kompleksitas pola sangat berpengaruh terhadap akurasi model.
- **Learning Rate:** *Learning Rate* sebesar 0.0001 dengan strategi *Exponential Decay* terbukti menghasilkan pembaruan bobot yang lebih halus selama

pelatihan. *Learning Rate* yang terlalu tinggi akan membuat model kesulitan mencapai konvergensi, sementara *Learning Rate* yang terlalu rendah dapat menyebabkan pelatihan berjalan terlalu lambat. *Learning Rate* 0.0001 memberikan keseimbangan yang optimal untuk mencegah model terjebak pada solusi lokal.

4.7.3. Pembahasan Model Inception-V3

Pada penelitian ini, model Inception-V3 digunakan untuk klasifikasi penyakit pada daun singkong dengan menerapkan teknik transfer learning dan optimasi hyperparameter menggunakan Grid Search. Hasil evaluasi menunjukkan bahwa model ini mampu melakukan klasifikasi dengan cukup baik.

Setelah proses training dan validasi, model Inception-V3 menghasilkan metrik evaluasi sebagai berikut:

- Akurasi: 91,56%
- Precision: 91,44%
- Recall: 91,38%
- F1-Score: 91,34%

Model ini menunjukkan kinerja yang baik dalam mengidentifikasi lima kelas penyakit daun singkong, yaitu:

1. *Cassava Mosaic Disease (CMD)*
2. *Cassava Brown Streak Disease (CBSD)*
3. *Cassava Bacterial Blight (CBB)*
4. *Cassava Green Mottle (CGM)*
5. *Healthy*

Dari hasil confusion matrix yang dihasilkan, sebagian besar prediksi berada pada kelas yang benar, namun terdapat beberapa kesalahan klasifikasi pada kelas yang memiliki kemiripan gejala visual, seperti antara CMD dan CGM.

Secara umum, Inception-V3 memiliki kemampuan yang baik dalam ekstraksi fitur, terutama fitur spasial pada gambar dengan ukuran yang kompleks. Namun, kekurangan dari model ini adalah kebutuhan komputasi yang cukup besar dan waktu training yang lebih lama dibandingkan model yang lebih ringan seperti MobileNet.

4.7.4. Pembahasan Model EfficientNet-B4

Model EfficientNet-B4 memberikan hasil yang lebih baik dibandingkan Inception-V3. Dengan memanfaatkan teknik compound scaling, model ini mampu menangkap informasi yang lebih kaya dari gambar dengan parameter yang lebih optimal.

Hasil evaluasi model EfficientNet-B4 adalah sebagai berikut:

- Akurasi: 94,28%
- Precision: 94,18%
- Recall: 94,09%
- F1-Score: 94,12%

Hasil ini menunjukkan bahwa model EfficientNet-B4 lebih akurat dalam mendeteksi penyakit daun singkong. Berdasarkan confusion matrix, jumlah kesalahan klasifikasi lebih rendah dibandingkan dengan model Inception-V3.

Model EfficientNet-B4 unggul dalam hal efisiensi komputasi dan akurasi yang tinggi, meskipun memiliki kompleksitas arsitektur yang lebih tinggi. Selain itu, teknik regularisasi yang diterapkan dalam EfficientNet, seperti drop connect dan swish activation, membantu mengurangi overfitting dan meningkatkan generalisasi model pada data uji.

4.7.5. Analisis Overfitting

Meskipun hasil akurasi validasi cukup baik, terdapat tanda-tanda *Overfitting* pada kedua model, yaitu *Inception-V3* dan EfficientNet-B4. *Overfitting* terjadi ketika model mempelajari pola pada data pelatihan dengan sangat baik, namun gagal menggeneralisasi pada data validasi. Hal ini terlihat dari perbedaan yang signifikan antara *Training Loss* dan *Validation Loss* pada kedua model. Pada model *Inception-V3*, *Overfitting* lebih terlihat, dengan *Training Accuracy* yang tinggi namun *Validation Accuracy* tidak meningkat secara signifikan. Sementara itu, *EfficientNet-B4* juga menunjukkan tanda-tanda *Overfitting*, namun dengan skala yang lebih kecil dibandingkan *Inception-V3*. *EfficientNet-B4* menunjukkan perbedaan yang lebih kecil antara *Training Loss* dan *Validation Loss*, menandakan bahwa model ini sedikit lebih baik dalam mengatasi *Overfitting* dan mampu menggeneralisasi data dengan lebih baik. *Overfitting* ini kemungkinan besar disebabkan oleh ketidakseimbangan dataset, di mana kelas *Cassava mosaic disease* memiliki lebih banyak gambar dibandingkan kelas lainnya.

4.8 Distribusi Dataset

4.8.1. Komposisi Dataset Sebelum Augmentasi

Dataset asli terdiri dari total 21.397 gambar dengan distribusi sebagai berikut:

Tabel 4. 2 Dataset Sebelum Augmentasi

Kelas	Jumlah Gambar	Persentase (%)
Cassava Mosaic Disease (CMD)	10000	46,75%
Cassava Brown Streak Disease (CBSD)	5000	23,37%
Cassava Bacterial Blight (CBB)	3000	14,02%
Cassava Green Mottle (CGM)	1800	8,41%
Healthy	1597	7,47%
Total	21397	100%

Kesimpulan: Dataset bersifat tidak seimbang, dengan kelas CMD mendominasi hampir separuh data.

4.8.2. Komposisi Dataset Setelah Augmentasi

Augmentasi diterapkan khusus pada kelas minoritas untuk menyeimbangkan jumlah data per kelas. Target augmentasi adalah menyamakan semua kelas ke jumlah 10.000 gambar per kelas. Hasilnya sebagai berikut:

Tabel 4. 3 Dataset Setelah Augmentasi

Kelas	Jumlah Setelah Augmentasi	Persentase (%)
Cassava Mosaic Disease (CMD)	10000	20,00%
Cassava Brown Streak Disease (CBSD)	10000	20,00%

Cassava Bacterial Blight (CBB)	10000	20,00%
Cassava Green Mottle (CGM)	10000	20,00%
Healthy	10000	20,00%
Total	50000	100%

Kesimpulan: Setelah augmentasi, dataset menjadi seimbang (balanced dataset) antar kelas.

4.8.3. Parameter Evaluasi Model

Evaluasi kinerja model dilakukan dengan menggunakan beberapa metrik evaluasi, yaitu Akurasi, Presisi, Recall, dan F1-Score. Berikut penjelasan masing-masing metrik:

1. Akurasi (Accuracy): Mengukur seberapa banyak prediksi yang benar dibandingkan dengan total jumlah data. Akurasi dihitung dengan rumus:

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN)$$

2. Presisi (Precision): Mengukur tingkat ketepatan dari prediksi positif yang benar dari keseluruhan prediksi positif.

$$\text{Precision} = TP / (TP + FP)$$


3. Recall (Sensitivity): Mengukur kemampuan model dalam menemukan semua kasus positif.

$$\text{Recall} = TP / (TP + FN)$$

4. F1-Score: Merupakan harmonic mean dari precision dan recall yang berguna saat data tidak seimbang.

$$\text{F1-Score} = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})$$

TP: True Positive, TN: True Negative, FP: False Positive, FN: False Negative.



BAB 5 PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian dan pembahasan, dapat ditarik kesimpulan sebagai berikut:


1. Perencanaan model klasifikasi penyakit daun singkong dengan arsitektur *Inception-V3* dan *EfficientNet-B4* berhasil dirancang melalui penerapan *transfer learning* dengan penyesuaian parameter (optimizer dan learning rate) menggunakan *grid search*.
2. Pelaksanaan eksperimen menunjukkan bahwa penggunaan data training dan validation dengan augmentasi meningkatkan kemampuan generalisasi model, sedangkan data testing tanpa augmentasi memberikan evaluasi yang objektif.
3. Hasil evaluasi performa model memperlihatkan bahwa baik *Inception-V3* maupun *EfficientNet-B4* mampu mengklasifikasikan penyakit daun singkong dengan cukup baik. Metrik akurasi, presisi, recall, dan F1-score menunjukkan performa yang kompetitif, dengan *EfficientNet-B4* cenderung lebih unggul pada dataset seimbang hasil augmentasi.
4. Penyetelan parameter dengan *grid search* terbukti berpengaruh terhadap peningkatan performa model, dimana kombinasi optimizer dan learning rate tertentu memberikan hasil yang lebih stabil dan akurat dibandingkan tanpa penyetelan sistematis.

5.2 Saran

Berdasarkan hasil dan temuan penelitian, saran-saran yang dapat diberikan untuk pengembangan lebih lanjut adalah sebagai berikut:

1. Peningkatan kualitas dataset, baik dari segi jumlah maupun keberagaman gambar. Dataset yang lebih besar dan seimbang antar kelas akan membantu model belajar lebih baik dan mengurangi masalah overfitting.
2. Menerapkan teknik regularisasi tambahan, seperti Dropout yang lebih agresif, L2 Regularization, atau Early Stopping dengan parameter yang lebih ketat, untuk mengurangi overfitting.
3. Eksplorasi teknik augmentasi yang lebih kompleks, misalnya CutMix, MixUp, atau Random Erasing, untuk meningkatkan generalisasi model.
4. Menggunakan model arsitektur yang lebih baru atau lebih kompleks, seperti EfficientNetV2, ResNet-152, Vision Transformer (ViT), atau model ensemble yang dapat menggabungkan kelebihan dari beberapa arsitektur.
5. Melakukan eksperimen dengan optimasi hyperparameter yang lebih luas, tidak hanya terbatas pada Batch Size, Learning Rate, dan Dense Units, tetapi juga mencoba berbagai optimizer seperti AdamW, Nadam, atau SGD dengan momentum.
6. Mengembangkan sistem deteksi berbasis aplikasi mobile atau website untuk mendukung petani dalam mendeteksi penyakit daun singkong secara lebih cepat dan praktis.

7. Untuk penelitian selanjutnya, disarankan tidak hanya fokus pada klasifikasi penyakit, tetapi juga menambahkan fitur segmentasi penyakit pada daun untuk mendapatkan informasi yang lebih spesifik terkait lokasi dan tingkat keparahan penyakit.



DAFTAR PUSTAKA

- [1] A. D. P. Ariyanto, S. Hasanah, M. B. Subkhi, and N. Suciati, "Analisis Penggunaan Pra-proses pada Metode Transfer Learning untuk Mendeteksi Penyakit Daun Singkong," *Techno.Com*, vol. 22, no. 2, Art. no. 2, May 2023, doi: 10.33633/tc.v22i2.7769.
- [2] "Indonesia Negara Penghasil Singkong Terbanyak Keempat Dunia," Dinas Komunikasi dan Informatika Provinsi Jawa Timur. Accessed: Jan. 24, 2024. [Online]. Available: <https://kominfo.jatimprov.go.id/berita/indonesia-negara-penghasil-singkong-terbanyak-keempat-dunia>
- [3] C. W. Miarti, Efri, M. S. Hadi, and R. Suharjo, "Identifikasi Penyakit Bercak Daun Coklat dan Busuk Umbi pada Tanaman Ubikayu (*Manihot esculenta* Crantz) akibat Penambahan Pupuk KCl dan 'Zincmicro,'" *Journal of Tropical Upland Resources (J. Trop. Upland Res.)*, vol. 2, no. 1, Art. no. 1, Jun. 2020, doi: 10.23960/jtur.vol2no1.2020.85.
- [4] M. Pangestika et al., *Smart Farming: Pertanian di Era Revolusi Industri 4.0*, Penerbit Andi, 2020.
- [5] A. Fahrezantara, S. Rizal, and N. K. C. Pratiwi, "Pemanfaatan Convolutional Neural Network Dalam Klasifikasi Penyakit Tanaman Singkong Menggunakan Arsitektur Densenet," *eProceedings of Engineering*, vol. 9, no. 6, Art. no. 6, Jan. 2023, Accessed: Jan. 24, 2024. [Online]. Available: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/19004>
- [6] M. Faturrachman, I. Yustiana, and Somantri, "SISTEM PENDETEKSI PENYAKIT PADA DAUN TANAMAN SINGKONG MENGGUNAKAN DEEP LEARNING DAN TENSORFLOW BERBASIS ANDROID," *IJIS - Indonesian Journal On Information System*, vol. 7, no. 2, Art. no. 2, Sep. 2022, doi: 10.36549/ijis.v7i2.225.
- [7] K. Chavez and L. Hernando, "Implementasi Sistem Pendeteksi Penyakit Pada Daun Singkong Dan Daun Cabai Berbasis Machine Learning," *JURNAL QUANCOM: QUANTUM COMPUTER JURNAL*, vol. 1, no. 2, Art. no. 2, Dec. 2023.
- [8] A. E. Nugraha, S. Rizal, and N. K. C. Pratiwi, "Klasifikasi Penyakit Pada Tanaman Singkong Menggunakan Arsitektur VGGNET Berbasis Deep Learning," *eProceedings of Engineering*, vol. 9, no. 6, Art. no. 6, Jan. 2023, Accessed: Jan. 24, 2024. [Online]. Available:

<https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/18990>

- [9] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *Journal of big Data*, vol. 8, pp. 1–74, 2021.
- [10] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson, "How transferable are features in deep neural networks?," *Advances in neural information processing systems*, vol. 27, 2014.
- [11] F. Zhuang *et al.*, "A Comprehensive Survey on Transfer Learning," *Proceedings of the IEEE*, vol. 109, no. 1, pp. 43–76, Jan. 2021, doi: 10.1109/JPROC.2020.3004555.
- [12] C. Wang *et al.*, "Pulmonary Image Classification Based on Inception-V3 Transfer Learning Model," *IEEE Access*, vol. 7, pp. 146533–146541, 2019, doi: 10.1109/ACCESS.2019.2946000.
- [13] A. Lianardo, S. Rizal, and N. K. C. Pratiwi, "Klasifikasi Gejala Penyakit Daun Pada Tanaman Singkong Berbasis Vision Menggunakan Metode CNN Dengan Arsitektur Mobilenet," *eProceedings of Engineering*, vol. 9, no. 6, Art. no. 6, Jan. 2023, Accessed: Jan. 24, 2024. [Online]. Available: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/18980>
- [14] A. Lianardo, S. Rizal, and N. K. C. Pratiwi, "Klasifikasi Gejala Penyakit Daun Pada Tanaman Singkong Berbasis Vision Menggunakan Metode CNN Dengan Arsitektur Mobilenet," *eProceedings of Engineering*, vol. 9, no. 6, Art. no. 6, Jan. 2023, Accessed: Mar. 17, 2024. [Online]. Available: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/18980>
- [15] M. H. Achmad and W. S. Rm, "Diabetic Retinopathy Severity Level Classification Based on Fundus Image Using Convolutional Neural Network (CNN)," *Seminar Nasional Informatika (SEMNASIF)*, vol. 1, no. 1, Art. no. 1, Nov. 2021.
- [16] M. F. Aslan, K. Sabanci, A. Durdu, and M. F. Unlarsen, "COVID-19 diagnosis using state-of-the-art CNN architecture features and Bayesian Optimization," *Comput Biol Med*, vol. 142, p. 105244, Mar. 2022, doi: 10.1016/j.combiomed.2022.105244.
- [17] B. Zhou and B. Arandian, "An Improved CNN Architecture to Diagnose Skin Cancer in Dermoscopic Images Based on Wildebeest Herd Optimization Algorithm," *Computational Intelligence and Neuroscience*, vol. 2021, Aug. 2021, doi: 10.1155/2021/7567870.

- [18] J. Rusman, B. Z. Haryati, and A. Michael, "Optimisasi Hiperparameter Tuning pada Metode Support Vector Machine untuk Klasifikasi Tingkat Kematangan Buah Kopi," *J-Icon: Jurnal Komputer dan Informatika*, vol. 11, no. 2, pp. 195–202, 2023.
- [19] A. Haris, "Otomasi penentuan nilai radioaktivitas radioisotop ^{241}Am , ^{137}Cs , dan ^{22}Na menggunakan multi-output machine learning," Fakultas Sains dan Teknologi UIN Syarif Hidayatullah Jakarta.
- [20] W. Nugraha and A. Sasongko, "Hyperparameter Tuning on Classification Algorithm with Grid Search," *Sistemasi: Jurnal Sistem Informasi*, vol. 11, no. 2, pp. 391–401, 2022.
- [21] N. Dong, L. Zhao, C. H. Wu, and J. F. Chang, "Inception v3 based cervical cell classification combined with artificially extracted features," *Applied Soft Computing*, vol. 93, p. 106311, Aug. 2020, doi: 10.1016/j.asoc.2020.106311.
- [22] "Multi-Label Classification of Fundus Images With EfficientNet | IEEE Journals & Magazine | IEEE Xplore." Accessed: Mar. 17, 2024. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/9268081>
- [23] Ü. Atila, M. Uçar, K. Akyol, and E. Uçar, "Plant leaf disease classification using EfficientNet deep learning model," *Ecological Informatics*, vol. 61, p. 101182, Mar. 2021, doi: 10.1016/j.ecoinf.2020.101182.
- [24] A. Baudin, M. Danisch, S. Kirgizov, C. Magnien, and M. Ghanem, "Cliques percolation method: memory efficient almost exact communities," arXiv.org. Accessed: Jun. 16, 2023. [Online]. Available: <https://arxiv.org/abs/2110.01213v1>
- [25] L. Chen, Y. Gao, X. Huang, C. S. Jensen, and B. Zheng, "Efficient Distributed Clustering Algorithms on Star-Schema Heterogeneous Graphs," *IEEE Transactions on Knowledge and Data Engineering*, vol. 34, no. 10, pp. 4781–4796, Oct. 2022, doi: 10.1109/TKDE.2020.3047631.
- [26] L. T. Duong, P. T. Nguyen, C. Di Sipio, and D. Di Ruscio, "Automated fruit recognition using EfficientNet and MixNet," *Computers and Electronics in Agriculture*, vol. 171, p. 105326, Apr. 2020, doi: 10.1016/j.compag.2020.105326.
- [27] G. Marques, D. Agarwal, and I. de la Torre Diez, "Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network," *Applied Soft Computing*, vol. 96, p. 106691, Nov. 2020, doi: 10.1016/j.asoc.2020.106691.
- [28] P. K. Das, S. S. Rupa, S. Purnin, U. C. Das, and M. K. Hossen, "Deep Learning for Plant Disease Detection and Classification: A Systematic Analysis and Review," *CURRENT APPLIED SCIENCE AND TECHNOLOGY*, pp. e0259016–e0259016, 2024.

- [29] R. Rajasree, C. B. C. Latha, S. Paul, M. Appu, and N. Aswathy, "An optimized Faster R-CNN model for Cassava Brown Streak Disease Classification," in *2023 3rd International Conference on Advances in Computing, Communication, Embedded and Secure Systems (ACCESS)*, IEEE, 2023, pp. 94–100.
- [30] A. Azeta, K. Jonathan, B. Guembe, and E. Nwadoziokwu, "A Deep Learning Approach For Cassava Leaf Disease Diagnosis," *Available at SSRN 4669543*, 2023.
- [31] D. Schaefer, B. Derat, A. Lauer, W. Simon, M. Celik, and T. Liebig, "Power Normalization for Over the Air Augmented Exposure Assessment," in *2024 15th German Microwave Conference (GeMiC)*, IEEE, 2024, pp. 81–84.
- [32] D. Das, S. K. Biswas, and S. Bandyopadhyay, "Detection of Diabetic Retinopathy using Convolutional Neural Networks for Feature Extraction and Classification (DRFEC)," *Multimed Tools Appl*, Nov. 2022, doi: 10.1007/s11042-022-14165-4.
- [33] M. F. Syahid, "Implementasi deep learning vgg16 dengan transfer learning pada deteksi penyakit tanaman singkong," bachelorThesis, Fakultas Sains dan Teknologi UIN Syarif Hidayatullah Jakarta, 2022. Accessed: Mar. 18, 2024. [Online]. Available: <https://repository.uinjkt.ac.id/dspace/handle/123456789/65121>
- [34] A. Maryum, M. U. Akram, and A. A. Salam, "Cassava Leaf Disease Classification using Deep Neural Networks," in *2021 IEEE 18th International Conference on Smart Communities: Improving Quality of Life Using ICT, IoT and AI (HONET)*, Oct. 2021, pp. 32–37. doi: 10.1109/HONET53078.2021.9615488.
- [35] U. K. Lilhore *et al.*, "Enhanced Convolutional Neural Network Model for Cassava Leaf Disease Identification and Classification," *Mathematics*, vol. 10, no. 4, Art. no. 4, Jan. 2022, doi: 10.3390/math10040580.
- [36] "Agriculture | Free Full-Text | Classification of Cassava Leaf Disease Based on a Non-Balanced Dataset Using Transformer-Embedded ResNet." Accessed: Mar. 18, 2024. [Online]. Available: <https://www.mdpi.com/2077-0472/12/9/1360>
- [37] P. K. Rao and E. Al, "Cassava Leaf Disease Classification using Separable Convolutions UNet," *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, vol. 12, no. 7, Art. no. 7, Apr. 2021.