

**PENERAPAN METODE PRUNING PADA ARSITEKTUR
RESNET-50 UNTUK MENINGKATAN KINERJA
KLASIFIKASI PADA PENYAKIT DAUN JAGUNG**

SKRIPSI

OLEH:

RABIATUL ADAWIYAH HSB

228160004



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS MEDAN AREA
MEDAN
2026**

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Document Accepted 1/7/26

Access From (repository.uma.ac.id)1/7/26

HALAMAN PENGESAHAN

Judul Skripsi : Penerapan Metode Pruning Pada Arsitektur Resnet-50 Untuk Meningkatkan Kinerja Pada Klasifikasi Penyakit Daun Jagung

Nama : Rabiatul Adawiyah Hasibuan
NPM : 228160004
Fakultas : Teknik Informatika

Disetujui Oleh
Komisi Pembimbing



Nurul Khairina S.kom, M.kom
Pembimbing I



Dr. Eng. Satrio ST, MT
Fakultas Teknik



Rizka Nurhono S.kom, M.kom
a. Prodi

Tanggal Lulus: 12 Maret 2026

HALAMAN PERNYATAAN

Saya menyatakan bahwa skripsi yang saya susun, sebagai syarat memperoleh gelar sarjana merupakan hasil karya tulis saya sendiri. Adapun bagian-bagian tertentu dalam penulisan skripsi ini yang saya kutip dari hasil karya orang lain telah dituliskan sumbernya secara jelas sesuai dengan norma, kaidah, dan etika penulisan ilmiah.

Saya bersedia menerima sanksi pencabutan gelar akademik yang saya peroleh dan sanksi-sanksi lainnya dengan peraturan yang berlaku, apabila di kemudian hari ditemukan adanya plagiat dalam skripsi ini.

Medan, 12 Maret 2026



Rabiatul Adawiyah Hsb
228160004

HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR/SKRIPSI/TESIS UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademik Universitas Medan Area, saya yang bertanda tangan di bawah ini:

Nama : Rabiatul Adawiyah Hsb
NPM : 228160004
Program Studi : Teknik Informatika
Fakultas : Teknik
Jenis Karya : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Medan Area **Hak Bebas Royalti Noneksklusif (*Non-exclusive Royalty-Free Right*)** atas karya ilmiah saya yang berjudul :

Penerapan Metode Pruning Pada Arsitektur *ResNet-50* Untuk Meningkatkan Klasifikasi Pada Penyakit Daun Jagung

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Medan Area berhak menyimpan, mengalihmedia/format-kan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan *Choose an item*. saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Medan
Pada tanggal : 12 Maret 2026
Yang menyatakan



Rabiatul Adawiyah Hsb
228160004

RIWAYAT HIDUP

Rabiatul Adawiyah hsb, lahir di Medan pada 26 Mei 2004, merupakan putri bungsu kesayangan Bapak Alm Idham Khalid Hsb S.H dan Ibu Hj.Masria Siregar. Perjalanan hidupnya tidaklah mudah; kehilangan sosok ayah tercinta sebelum menginjak bangku SMK menjadi ujian kedewasaan yang membentuknya menjadi pribadi yang tangguh. Meski melangkah tanpa bimbingan langsung dari sang ayah, Khairul membuktikan bahwa rindu bisa diubah menjadi energi. Dari SMKN1 Percut Sei Tuan, ia melanjutkan langkah ke Teknik Informatika Universitas Medan Area pada 2022.

Kemandiriannya membawanya aktif mengejar ilmu melalui berbagai *bootcamp* dan organisasi sebagai Sekretaris Divisi Medkom HMIF. Puncaknya, ia merayakan kemenangannya atas masa sulit dengan terpilih sebagai penerima Beasiswa Bank Indonesia (GenBI) 2025-2026. Skripsi ini adalah persembahan cintanya untuk ibu dan sebuah janji yang ia tepati untuk mendiang ayahnya.



KATA PENGANTAR

Dengan penuh rasa syukur ke hadirat Allah Subhanahu wa Ta'ala atas segala berkat, rahmat, dan hidayah-Nya, penulis akhirnya dapat menyelesaikan skripsi dengan judul "**Penerapan Metode Pruning pada Arsitektur ResNet-50 untuk Meningkatkan Kinerja Klasifikasi pada Penyakit Daun Jagung**". Skripsi ini disusun sebagai salah satu syarat untuk menyelesaikan pendidikan Program Strata-1 pada Fakultas Teknik Program Studi Teknik Informatika di Universitas Medan Area. Penulis menyadari bahwa meskipun skripsi ini telah disusun dengan sebaik-baiknya, masih terdapat banyak kekurangan dan jauh dari kata kesempurnaan. Oleh karena itu, penulis sangat mengharapkan kritik dan saran yang bersifat konstruktif dari para pembaca untuk perbaikan di masa yang akan datang. Penulis juga ingin menyampaikan rasa terima kasih yang sebesar-besarnya kepada:


1. Allah SWT yang senantiasa menyertai setiap langkah hidup penulis, memberikan kekuatan, kesabaran, dan kemudahan sehingga penulis dapat menyelesaikan pendidikan ini dengan baik.
2. Bapak Prof. Dr. Dadan Ramdan, M.Eng., M.Sc., selaku Rektor Universitas Medan Area.
3. Bapak Dr. Eng. Supriatno, S.T., M.T., selaku Dekan Fakultas Teknik Universitas Medan Area.
4. Bapak Rizki Muliono, S.Kom., M.Kom., selaku Kepala Program Studi Teknik Informatika.
5. Bapak Muhathir, S.T., M.Kom., selaku dosen pembimbing yang telah membimbing, mengarahkan, dan memberikan motivasi kepada penulis dalam proses menyelesaikan skripsi ini.
6. Seluruh Dosen Teknik Informatika Universitas Medan Area yang telah membekali penulis dengan ilmu yang sangat bermanfaat.
7. Bapak Robby Kurniawan Sari Damanik, S.T., selaku IT Support Teknik Informatika yang selalu mengarahkan penulis dalam urusan administrasi.

8. Teruntuk Cinta Pertama dan Panutanku Almarhum Ayah Tercinta, Beliau Memang tidak sempat menemani Penulis dalam Menyusun Skripsi, namun selama hidupnya telah menjadi sosok panutan, sumber semangat, dan inspirasi yang tak tergantikan. Doa-doa Ayah, Didikan, dan nilai-nilai kehidupan yang sudah ayah tanamkan akan selalu hidup dalam diri penulis. Alhamdulillah, Penulis kini telah sampai pada tahap ini, Menyelesaikan karya tulis sederhana ini sebagai bentuk persembahan untuk Ayah dan bukti tanggung jawab bahwa penulis telah melanjutkan Pendidikan seperti yang ayah harapkan, walaupun penulis masih mengharapkan genggam tangan mu saat hampir menyerah. Dan pintu surgaku ibuku tercinta yang hatinya seluas lautan, pengorbanan yang tak terhingga terimakasih telah memberikan segalanya hingga penulis mampu menyelesaikan studinya sampai meraih gelar sarjana. Tanpamu penulis bukan lah apa-apa, Besar harapan penulis semoga ibu selalu sehat, Panjang umur, dan bisa menyaksikan keberhasilan lainnya yang akan penulis raih dimasa depan yang akan datang.
9. Serta Tak lupa untuk ketiga saudara perempuan ku, terima kasih support nya tidak pernah terpikir penulis untuk tidak membalas. kakak dengan penuh keikhlasan telah memenuhi setiap kebutuhan, fasilitas dan energi yang tak pernah habis untuk nasehat setiap saat, Terima kasih telah memberikan peran pelindung, penyemangat, dan penopang di saat penulis hilang arah.
10. Juga bebrapa saudara laki-laki serta ayah keponakan penulis, perhatian dan dukungan yang tulus telah menjadi sumber kekuatan yang menuntun penulis mampu menyelesaikan karya tulis ini, penulis berharap kesederhanaan, kehangatan, dan kebersamaan ini bertahan sampai kapan pun.
11. Teman-teman seangkatan dan seorganisasi yang dengan sabar menemani penulis melewati masa-masa kelam, Terima kasih telah menjadi system pendukung yang luar biasa, memberikan hiburan disaat suka duka, dan pengalaman luar biasa dalam dunia perkuliahan. Penulis berharap semua nya menjadi orag yang suksse dimasa depan
12. Untuk seseorang yang belum bisa kutulis dengan jelas Namanya disini, namun sudah tertulis jelas di *Lauhul Mahfudz* untukku. Terima kasih sudah

menjadi salah satu motivasi penuli dalam menyelesaikan Karya Tulis Ilmiah ini sebagai salah satu bentuk penulis dalam memantaskan diri. Meskipun saat ini penulis tidak tahu keberadaan mu entah di Bumi belahan bagian mana dan menggenggam tangan siapa. Seperti kata BJ Habibie “kalau memang dia dilahirkan untuk saya, kamu jungkir balik pun saya yang dapat” (meskipun di hati kecil yang paling dalam saya mengharapkan 1 nama kepada mu ya allah).

13. Last but no least. Terima kasih untuk Rabiatul Adawiyah, diri saya sendiri yang telah bekerja keras dan berjuang sejauh ini. Mampu mengendalikan diri dari berbagai tekanan luar keadaan dan tak pernah memutuskan menyerah sesulit apapun Proses penyusunan Karya Tulis Ilmiah ini dengan menyelesaikan sebaik dan semaksimal mungkin, ini merupakan pencapaian yang patut dibanggakan untuk diri sendiri. Semoga kedepannya saya lebih mencitai diri sendiri.

Medan , 09, Maret 2026



Rabiatul Adawiyah Hsb
228160004

ABSTRACT

Early detection of corn leaf diseases is an important step in minimizing crop yield reduction and preventing agricultural losses. This study aims to classify corn leaf diseases by applying a compression method using pruning techniques integrated into the Deep Learning algorithm with the ResNet-50 architecture. The data used consists of corn leaf images divided into four classes, namely Gray Leaf Spot, Healthy, Northern Leaf Blight, and Common Rust. The research methods include data collection, image preprocessing, data augmentation, the application of Unstructured Pruning (L1-Norm) and Structured Pruning (L2-Norm) at pruning ratios of 40%, 50%, 60%, and 70%, the fine-tuning process, and evaluation using the Confusion Matrix and model size efficiency. The results show that the baseline model achieved an accuracy rate of 98.50% with a size of 90 MB. In the Unstructured Pruning focus, the best configuration was achieved at a 60% ratio with an accuracy of 99.50% and a size of 42 MB. Meanwhile, for Structured Pruning, the optimal configuration yielded 99.00% accuracy and a size of 45 MB at a 50% ratio, demonstrating the effectiveness of model compression for classification. Consequently, the obtained model optimization provides accurate classification performance for corn leaf diseases with a significantly lighter computational load.

Keywords: *Corn Leaf Disease, Deep Learning, Image Classification, Pruning, ResNet-50.*

ABSTRAK

Deteksi dini penyakit pada daun jagung merupakan langkah penting dalam meminimalisir penurunan hasil panen dan mencegah kerugian pertanian. Penelitian ini bertujuan untuk melakukan klasifikasi penyakit daun jagung dengan menerapkan metode kompresi menggunakan teknik *pruning* yang diintegrasikan ke dalam algoritma *Deep Learning* dengan arsitektur ResNet-50. Data yang digunakan berupa citra daun jagung yang terbagi menjadi empat kelas, yaitu Bercak Daun, Daun Sehat, Hawar Daun, dan Karat Daun. Metode penelitian meliputi pengumpulan data, pra-pemrosesan citra, augmentasi data, penerapan *Unstructured Pruning* (L1-Norm) dan *Structured Pruning* (L2-Norm) dengan rasio pemangkasan 40%, 50%, 60%, dan 70%, proses pelatihan ulang (*fine-tuning*), serta evaluasi menggunakan *Confusion Matrix* dan efisiensi ukuran model. Hasil penelitian menunjukkan bahwa pada model *baseline* diperoleh tingkat akurasi sebesar 98,50% dengan ukuran 90 MB, sedangkan pada fokus *Unstructured Pruning* diperoleh konfigurasi terbaik pada rasio 60% dengan nilai akurasi 99.50% dan ukuran 42 MB, serta pada *Structured Pruning* diperoleh konfigurasi optimal dengan nilai akurasi 99,00% dan ukuran 45 MB pada rasio 50% yang mampu menggambarkan efektivitas kompresi model klasifikasi. Dengan demikian, hasil optimalisasi model yang diperoleh dapat memberikan performa klasifikasi penyakit daun jagung yang akurat dengan beban komputasi yang jauh lebih ringan.

Kata Kunci: *Deep Learning*, Klasifikasi Citra, Penyakit Daun Jagung, *Pruning*, *ResNet-50*.

DAFTAR ISI

HALAMAN PENGESAHAN.....	i
HALAMAN PERNYATAAN.....	ii
RIWAYAT HIDUP	iv
KATA PENGANTAR.....	v
ABSTRACT	viii
ABSTRAK	ix
DAFTAR ISI.....	x
DAFTAR TABEL	xii
DAFTAR GAMBAR.....	xiii

BAB I PENDAHULUAN.....	1
1.1. Latar Belakang	1
1.2. Rumusan Masalah	5
1.3. Batasan Masalah.....	5
1.4. Tujuan Penelitian.....	6
1.5. Manfaat Penelitian.....	6

BAB II TINJAUAN PUSTAKA.....	7
2.1. <i>Deep Learning</i>	7
2.2. <i>Convolutional Neural Network (CNN)</i>	9
2.2.1. <i>Input Layer</i>	10
2.2.2. <i>Convolution Layer</i>	10
2.2.3. <i>Pooling layer</i>	11
2.2.4. <i>Fully Connected Layer</i>	12
2.3. <i>ResNet-50</i>	13
2.4. <i>Network Pruning</i>	16
2.4.1. Klasifikasi Teknik <i>Pruning</i>	17
2.4.2. Kriteria <i>Pruning</i>	18
2.4.3. Magnitude-Based Pruning (<i>L1-Norm – L2-Norm</i>)	18
2.5. Pengoptimasi (<i>Optimizer</i>).....	20
2.6. Metode Evaluasi	22
2.7. Penelitian Terdahulu.....	24

BAB III METODOLOGI PENELITIAN	28
3.1. Diagram Alur Penelitian.....	28
3.2. Metode Pengumpulan Data	29
3.3. Pra-pemrosesan Data (<i>Data Preprocessing</i>)	30

3.3.2.	Augmentasi Data (<i>Data Augmentation</i>)	31
3.4.	Penerapan <i>Pruning</i> Pada <i>ResNet-50</i>	32
3.4.2.	Perhitungan Manual <i>Pruning</i>	35
3.5.	Pembagian Data	36
3.6.	<i>Hyperparameter</i>	38
3.7.	Ruang Lingkup Pengujian	39
3.7.1.	Perangkat Keras	39
3.7.2.	Perangkat Lunak	40
BAB IV HASIL DAN PEMBAHASAN		41
4.1.	Hasil Pengujian Model Baseline	41
4.2.	Hasil Penerapan <i>Unstructured Pruning</i>	43
4.3.	Hasil Penerapan <i>Strucured Pruning</i>	45
4.4.	Pembahasan	48
4.5.	Perbandingan Kinerja Metode Pruning	49
4.6.	Perbandingan Peneitian Terdahulu	51
4.7.	Implementasi Sistem Klasifikasi Berbasis Web	51
4.8.	Keterbatasan penelitian	54
BAB V KESIMPULAN DAN SARAN		56
5.1.	Kesimpulan	56
5.2.	Saran	57
5.3.	Implikasi dan Dampak	58
DAFTAR PUSTAKA		60


DAFTAR TABEL

	Halaman
Tabel 2.1. <i>ResNet50 network parameters</i>	14
Tabel 2.2. <i>Confusion Matrix</i>	22
Tabel 2.3. Penelitian Terdahulu.....	24
Tabel 3.1. Jumlah <i>Dataset</i>	29
Tabel 3.2. Pembagian Data Latih, Validasi, dan Uji.....	37
Tabel 3.3. <i>Hyperparameter</i>	38
Tabel 3.4. Tabel Perangkat Keras	39
Tabel 3.5. Tabel Perangkat Lunak	40
Tabel 4.1. Hasil Pengujian <i>Baseline</i>	42
Tabel 4.2. Performa Model <i>Baseline</i> Berdasarkan Kelas <i>Citra</i>	42
Tabel 4.3. Hasil Evaluasi Akhir Penerapan <i>Unstructured Pruning</i>	43
Tabel 4.3. Hasil Evaluasi Akhir Penerapan <i>Structured Pruning</i>	45
Tabel 4.2. Rekapitulasi Perbandingan Performa Arsitektur <i>ResNet50</i>	46
Tabel 4.3. Rekapitulasi Perbandingan Kinerja Metode <i>Pruning</i>	50
Tabel 4.4. Perbandingan Hasil Penelitian terdahulu	51



DAFTAR GAMBAR

	Halaman
Gambar 2.1 Arsitektur CNN	10
Gambar 2.2 Arsitektur <i>ResNet50</i>	14
Gambar 3.1 Alur Penelitian.....	28
Gambar 3.2 Contoh Dataset Penyakit Pada Daun jagung	30
Gambar 3.3 Contoh Augmentasi data	32
Gambar 3.4 Pruning Pada <i>ResNet50</i>	32
Gambar 4.1 Hasil Evaluasi <i>Confusion Matrix</i> dan <i>ROC</i> pada <i>Model Baseline</i> ...	43
Gambar 4.2 <i>Confusion Matrix</i> dan Kurva <i>ROC Unstructured Pruning</i>	44
Gambar 4.3. <i>Confusion Matrix</i> dan Kurva <i>ROC Structured Pruning</i>	46
Gambar 4.4 Tampilan Halaman Utama (Beranda) Sistem Klasifikasi	52
Gambar 4.5 Tampilan Antarmuka Fitur Unggah Citra Daun Jagung	53
Gambar 4.6 Tampilan Antarmuka Hasil Diagnosa Citra Daun Jagung	53



BAB I PENDAHULUAN

1.1. Latar Belakang

Pertanian merupakan salah satu sektor fundamental dalam mendukung ketahanan pangan nasional, khususnya komoditas jagung yang memiliki nilai strategis baik sebagai bahan pangan utama, pakan ternak, maupun bahan baku industri (Zia et al., 2023). Seiring dengan bertambahnya populasi penduduk, kebutuhan jagung di Indonesia terus mengalami peningkatan yang signifikan setiap tahunnya. Untuk memenuhi permintaan pasar yang tinggi tersebut, stabilitas dan kualitas produksi jagung harus dijaga secara optimal. Salah satu ancaman terbesar yang dapat menghambat produktivitas jagung adalah serangan hama dan penyakit tanaman. Penyakit yang menyerang bagian daun—seperti Bercak Daun, Hawar Daun, dan Karat Daun, dapat menurunkan hasil panen secara drastis karena daun merupakan organ vital yang berperan penting dalam proses fotosintesis dan transportasi nutrisi (Hatem et al., 2023). Jika tidak ditangani dengan cepat, infeksi ini dapat menyebar ke seluruh lahan dan menyebabkan gagal panen yang merugikan petani secara ekonomi. Kondisi ini menunjukkan bahwa sistem deteksi penyakit yang cepat, tepat, dan akurat merupakan kebutuhan mendesak dalam upaya menjaga ketahanan pangan nasional (Noola & Basavaraju, 2022).

Namun, realitanya di lapangan, deteksi dini penyakit tanaman masih menghadapi berbagai tantangan teknis. Hingga saat ini, mayoritas petani di Indonesia masih mengandalkan metode identifikasi penyakit secara manual melalui pengamatan visual langsung (Pramono et al., 2024). Metode konvensional ini

memiliki banyak kelemahan. Selain membutuhkan waktu yang lama untuk memonitor lahan yang luas, identifikasi manual sangat bergantung pada keahlian dan pengalaman individu petani atau penyuluh lapangan yang jumlahnya terbatas. Hal ini memunculkan risiko subjektivitas yang tinggi dan inkonsistensi dalam diagnosis, terutama karena beberapa gejala penyakit memiliki kemiripan visual pada tahap infeksi awal (Shafay et al., 2025). Kesalahan diagnosis dapat berakibat fatal pada kesalahan pemilihan jenis pestisida atau metode penanganan, yang justru dapat memperburuk kondisi tanaman dan mencemari lingkungan.

Seiring dengan kemajuan teknologi, pemanfaatan kecerdasan buatan (*Artificial Intelligence*) menjadi solusi menjanjikan untuk mengatasi keterbatasan manusia tersebut. Kemunculan alat pengenalan penyakit tanaman berbasis citra digital dapat membantu diagnosis dini secara signifikan, didukung oleh perkembangan *smartphone* yang mampu menangkap gambar berkualitas tinggi (Ngugi et al., 2021). Dalam beberapa tahun terakhir, metode klasifikasi berbasis *Deep learning* berkembang pesat dan menjadi standar baru dalam *computer vision* (Alirezazadeh et al., 2022). Pendekatan ini mampu membangun representasi data yang kompleks dan hierarkis secara mandiri. Salah satu algoritma *Deep learning* yang paling unggul adalah *Convolutional Neural Network* (CNN) (Bulawit et al., 2023). Berbeda dengan metode *Machine Learning* tradisional yang membutuhkan ekstraksi fitur manual yang rumit, CNN memiliki kemampuan *feature learning* otomatis melalui lapisan konvolusi, sehingga dapat mengenali pola visual penyakit seperti tekstur, warna, dan bentuk lesi pada daun dengan akurasi yang sangat tinggi (Mamatha & Raju, 2025).

Di antara berbagai varian arsitektur CNN, ResNet (*Residual Network*) menjadi salah satu model yang paling populer dan sering digunakan dalam penelitian klasifikasi citra medis maupun pertanian. Keunggulan utama ResNet terletak pada arsitekturnya yang menggunakan mekanisme *skip connections* atau *residual blocks*, yang memungkinkan pelatihan jaringan yang sangat dalam tanpa mengalami masalah hilangnya gradien (*vanishing gradient*) (Musale et al., 2025). Secara spesifik, varian *ResNet50* yang memiliki kedalaman 50 lapisan dirancang untuk menangkap fitur citra yang sangat detail secara bertingkat, mulai dari fitur dasar seperti garis hingga fitur semantik kompleks. Efektivitas *ResNet50* telah dibuktikan dalam berbagai studi terdahulu. Sebagai contoh, penelitian Jayaraman & Palaniyandi (2025) pada klasifikasi penyakit daun padi berhasil mencapai akurasi 96,48%. Studi lain oleh Ahmed El-Massry et al. (2024) pada daun kentang memperoleh akurasi 91,5%, serta penelitian Raj et al. (2024) pada citra glaukoma yang mencapai akurasi 90%.

Meskipun berbagai penelitian terdahulu telah membuktikan bahwa *ResNet50* mampu mencapai tingkat akurasi yang superior, model ini memiliki kelemahan mendasar dari sisi efisiensi sumber daya. *ResNet50* dikenal sebagai model yang "berat" karena memiliki struktur yang dalam dan jumlah parameter yang sangat besar, mencapai lebih dari 23 juta parameter (Shi et al., 2025). Hal ini menyebabkan model membutuhkan kapasitas memori penyimpanan yang besar dan daya komputasi yang tinggi untuk proses inferensi. Sayangnya, mayoritas penelitian sebelumnya hanya berfokus mengejar angka akurasi tertinggi tanpa mempertimbangkan aspek efisiensi ini. Keterbatasan ini menjadi kendala serius ketika model tersebut hendak diimplementasikan pada skenario nyata di sektor

pertanian, seperti pada aplikasi seluler di *smartphone* petani dengan spesifikasi menengah ke bawah atau perangkat IoT (*Edge Computing*) di lahan terpencil yang memiliki keterbatasan memori, baterai, dan koneksi internet (L. Ma et al., 2023).

Permasalahan *trade-off* antara akurasi tinggi dan efisiensi komputasi inilah yang melatarbelakangi perlunya strategi optimalisasi model. Salah satu solusi teknis yang relevan adalah penerapan teknik *Model Pruning*. *Pruning* adalah metode kompresi model yang bekerja dengan cara memangkas atau menghapus koneksi (bobot) antar-neuron yang dianggap tidak penting atau bernilai mendekati nol, tanpa merusak struktur utama jaringan (Narkhede et al., 2024). Dengan teknik ini, ukuran model dapat diperkecil secara signifikan dan waktu eksekusi program menjadi lebih cepat, namun kemampuan model dalam mengenali pola penyakit tetap terjaga (T. Yu et al., 2023).

Berdasarkan uraian permasalahan di atas, penelitian ini berkontribusi dengan menerapkan teknik *model pruning* pada arsitektur *ResNet50* untuk klasifikasi penyakit daun jagung. Penelitian ini tidak hanya bertujuan membangun model cerdas, tetapi juga menghasilkan kontribusi nyata berupa model yang seimbang antara kecepatan dan ketepatan. Fokus utama penelitian terletak pada analisis komparatif kinerja model sebelum dan sesudah *pruning*, baik dari aspek akurasi klasifikasi, pengurangan ukuran penyimpanan, maupun percepatan waktu deteksi. Dengan demikian, hasil penelitian ini diharapkan dapat menjadi rujukan penting dalam pengembangan teknologi pertanian cerdas (*Smart Farming*) yang *lightweight* (ringan) dan dapat diterapkan secara nyata (*deployable*) untuk mendukung produktivitas petani di Indonesia.

1.2. Rumusan Masalah

Berdasarkan penjelasan masalah yang telah dipaparkan pada latar belakang, rumusan masalah dalam penelitian ini adalah:

Bagaimana kinerja model *ResNet-50* dengan penerapan teknik *Structured pruning* dan *Unstructured pruning* dalam mengklasifikasikan penyakit daun jagung berdasarkan citra daun.

1.3. Batasan Masalah

Adapun yang menjadi batasan masalah pada penelitian ini yaitu sebagai berikut:

1. Data yang digunakan berupa data *sekunder* berupa citra daun jagung yang diperoleh dari situs *Kaggle*, yaitu *Corn Leaf Disease Dataset* (<https://www.Kaggle.com/Datasets/ndisan/corn-leaf-disease>).
2. *Dataset* yang digunakan berjumlah 4000 citra, terdiri dari 4 kelas penyakit daun jagung, dengan masing-masing kelas berjumlah 1000 citra.
3. Pembagian *Dataset* dilakukan dengan proporsi data *training* 70%, data *validation* 15%, dan data *testing* 15%.
4. Citra daun yang digunakan berformat *JPG*.
5. Arsitektur jaringan saraf yang digunakan adalah *ResNet-50*.
6. Teknik optimasi model yang diterapkan adalah *Unstructured pruning* dan *Structured pruning* pada arsitektur *ResNet-50*.
7. *Optimizer* yang digunakan dalam proses pelatihan model adalah *ADAM*.
8. Bahasa pemrograman yang digunakan dalam penelitian ini adalah *Python*.

1.4. Tujuan Penelitian

Berdasarkan rumusan masalah, tujuan dari penelitian ini adalah untuk mengembangkan dan mengevaluasi seberapa efektif penerapan teknik *pruning* pada arsitektur *ResNet-50* dalam meningkatkan efisiensi dan kinerja klasifikasi penyakit daun jagung berbasis citra.

1.5. Manfaat Penelitian

Penelitian ini diharapkan dapat memperkaya ilmu *deep learning* melalui penerapan arsitektur *ResNet-50* dengan teknik *Unstructured pruning* dalam klasifikasi penyakit daun jagung. Dengan menerapkan *pruning* pada *ResNet-50*, diharapkan dapat dihasilkan model yang lebih ringan dan efisien tanpa penurunan performa klasifikasi yang signifikan, sehingga berkontribusi pada pengembangan model *deep learning* yang lebih efektif.

BAB II

TINJAUAN PUSTAKA

2.1. *Deep Learning*

Deep learning adalah bagian dari *machine learning* yang berfokus pada penggunaan jaringan saraf tiruan (*artificial neural networks*) dengan banyak lapisan untuk mempelajari representasi data yang kompleks. Berbeda dengan pendekatan tradisional yang membutuhkan rekayasa fitur secara manual, *Deep learning* mampu secara otomatis mengekstraksi fitur penting dari data mentah, seperti gambar, suara, atau teks (Aston Zhang, Zachary C. Lipton, 2025). Sistem berbasis *Deep learning* memiliki kemampuan adaptif dalam mengenali pola visual, termasuk untuk tugas-tugas klasifikasi citra. Salah satu penerapannya adalah dalam bidang identifikasi tanaman, di mana sistem ini dapat membantu pengguna mengenali jenis tanaman melalui citra daun tanpa memerlukan keahlian botani secara langsung (Geerthana et al., 2021).

Sebagai teknologi kecerdasan buatan yang terus berkembang, *Deep learning* memiliki potensi besar untuk meningkatkan efisiensi dan akurasi di berbagai sektor, terutama pada bidang deteksi citra. Keunggulan utamanya terletak pada kemampuannya mempelajari pola dan hubungan kompleks dari data dalam skala besar tanpa memerlukan instruksi pemrograman eksplisit (Tehsin et al., 2023). Selain itu, *Deep learning* dapat dijalankan secara optimal pada perangkat keras dengan daya komputasi tinggi, seperti GPU (*Graphics Processing Unit*), yang memungkinkan pemrosesan data dalam jumlah besar dengan efisien. Kekuatan tersebut telah mendorong terjadinya kemajuan signifikan dalam penyelesaian

berbagai permasalahan yang sebelumnya menjadi tantangan dalam komunitas kecerdasan buatan (Sutinah et al., 2025).

Deep learning terbukti unggul dalam menemukan struktur yang kompleks pada data berdimensi tinggi, sehingga aplikasinya meluas ke berbagai domain seperti ilmu pengetahuan, hingga pemerintahan (DELL, 2024). Dalam bidang biomedis, teknologi ini berkontribusi besar dalam memprediksi aktivitas molekul obat potensial, menganalisis data akselerator partikel, merekonstruksi sirkuit neural otak, hingga memproyeksi efek mutasi DNA terhadap ekspresi gen dan penyakit (Guo, 2024). Selain pada data visual dan biologis, model ini menunjukkan kinerja luar biasa dalam ranah pemrosesan bahasa alami atau *Natural Language Processing* (NLP) yang mencakup tugas-tugas linguistik seperti klasifikasi topik, analisis sentimen, sistem penjawab pertanyaan, hingga penerjemahan antarbahasa (Bansod et al., 2025).


Secara komprehensif, *Deep learning* merepresentasikan fondasi utama dalam kemajuan teknologi kecerdasan buatan modern. Kemampuannya dalam melakukan ekstraksi, pemahaman, dan generalisasi pola dari data yang sangat kompleks mengukuhkan posisinya sebagai salah satu pendekatan paling efektif dan adaptif di era komputasi berbasis data saat ini. Melalui integrasi antara algoritma yang canggih dan kekuatan komputasi modern, *Deep learning* terus menjadi pendorong utama inovasi dalam menyelesaikan permasalahan teknis yang sebelumnya dianggap tidak mungkin terpecahkan (Halim et al., 2025).

2.2. Convolutional Neural Network (CNN)

Jaringan Saraf Konvolusional (*Convolutional Neural Network* /CNN) merupakan salah satu model pembelajaran mesin yang efektif dalam mengekstraksi fitur dari data untuk melakukan tugas prediksi, baik regresi maupun klasifikasi (Jiang & Zavala, 2021). CNN pertama kali diperkenalkan pada tahun 1960-an dan telah menunjukkan kinerja yang sangat baik dalam bidang visi komputer, terutama karena mekanisme pembagian bobot (*weight sharing*) dan konektivitas yang jarang (*sparse interaction*) (Ma et al., 2025). Arsitektur CNN umumnya terdiri dari tiga jenis lapisan utama, yaitu lapisan konvolusional dengan fungsi aktivasi nonlinier, lapisan *pooling*, dan lapisan *fully connected*. Lapisan konvolusional berfungsi untuk mengekstrak fitur dari citra masukan dengan cara menerapkan *filter* konvolusi pada peta fitur, sementara fungsi aktivasi nonlinier memungkinkan model mempelajari pola yang kompleks. Struktur ini memungkinkan CNN melakukan komputasi secara efisien dan menghemat waktu pemrosesan (Purwono et al., 2022).

Setelah proses pelatihan, CNN mampu melakukan prediksi secara cepat dan akurat hanya berdasarkan data citra, sehingga banyak digunakan dalam berbagai aplikasi pengenalan visual (Wu et al., 2023). Dalam konteks klasifikasi citra, CNN telah terbukti unggul dalam mengekstrak representasi fitur secara otomatis dan mencapai tingkat akurasi yang tinggi, termasuk dalam identifikasi penyakit tanaman dari citra daun (Hindarto, 2023). Kemampuan CNN dalam mengenali pola visual menjadikannya metode yang efektif untuk mendeteksi penyakit tanaman jagung pada tahap awal. Penerapan teknologi ini diharapkan dapat membantu petani dalam mengambil tindakan pengendalian yang tepat, meningkatkan akurasi

perlindungan tanaman, serta mendukung pengembangan pertanian presisi (Saleem et al., 2022)



Gambar 2.1 Arsitektur CNN

Sumber (Saleem et al., 2022)

Secara umum, jaringan ini mengambil input dari piksel atau grid citra atau gambar, Struktur jaringan saraf konvolusi memiliki empat lapisan utama, yaitu:

2.2.1. *Input Layer*

Pada lapis ini merupakan tinjauan sebuah citra atau gambar untuk menjadi input bagi jaringan saraf konvolusi (Cong & Zhou, 2023). Citra merupakan representasi secara visual suatu objek dalam bentuk matriks atau array yang terbangun dari elemen-elemen pecahan citra yang disebut piksel. Lapisan masukan merupakan lapisan pertama yang menerima masukan data kemudian diteruskan pada lapisan berikutnya. Dimensi *Input Layer* jaringan saraf konvolusi mengikuti format: *height x width x channel*. Misalnya untuk format citra RGB: (28, 28, 3) dan format *Greyscale*: (28,28,1) (Taye, 2023).

2.2.2. *Convolution Layer*

Lapisan konvolusi merupakan komponen utama dalam *Convolutional Neural Network* (CNN) yang berfungsi untuk mengekstraksi pola dan fitur penting dari data masukan. Lapisan ini bekerja dengan menerapkan sejumlah *filter* yang dapat

dipelajari untuk mendeteksi karakteristik tertentu, seperti tepi, tekstur, dan bentuk. Setiap *filter* menghasilkan peta fitur yang merepresentasikan informasi spesifik dari citra masukan (Iqbal et al., 2023).

Secara matematis, operasi konvolusi dapat dirumuskan sebagai berikut (Mienye et al., 2025):

$$F(i, j) = (G * H)(i, j) = \sum_m \sum_n G(m, n)H(i - m, j - n), \quad (2.1)$$

dengan $F(i, j)$ menyatakan peta fitur keluaran pada posisi (i, j) , $G(m, n)$ citra masukan, dan $H(i - m, j - n)$ adalah kernel atau *filter* yang diterapkan pada citra tersebut. Indeks m dan n menunjukkan dimensi spasial dari kernel, yaitu tinggi dan lebarnya.

Dalam proses ini, kernel digeser secara sistematis ke seluruh bagian citra masukan untuk menghitung hasil perkalian dan penjumlahan antara bobot *filter* dan nilai piksel yang bersesuaian. Mekanisme tersebut memungkinkan jaringan mengekstraksi fitur spasial yang relevan dan membentuk pembelajaran fitur secara bertingkat dalam arsitektur CNN. Untuk meningkatkan kemampuan jaringan dalam mempelajari pola yang lebih kompleks, fungsi aktivasi Rectified Linear Unit (ReLU) umumnya diterapkan setelah operasi konvolusi guna menambahkan sifat non-linear pada model (Iqbal et al., 2023).

2.2.3. Pooling layer

Lapisan *pooling* berfungsi untuk mengurangi ukuran spasial dari peta fitur, sehingga dapat menurunkan kompleksitas komputasi dan meningkatkan ketahanan jaringan terhadap variasi posisi pada data masukan (Zafar et al., 2022). Dengan melakukan peringkasan informasi pada area tertentu, lapisan ini membantu

mempertahankan fitur-fitur penting sekaligus mengurangi jumlah parameter yang harus diproses. Salah satu metode *pooling* yang paling umum digunakan adalah *max pooling*, yaitu proses pengambilan nilai maksimum dari suatu wilayah pada peta fitur (Akgül, 2024).

Operasi ini dapat dirumuskan sebagai berikut (Mienye et al., 2025):

$$P_{ij} = \max_{a,b \in \mathcal{N}_{ij}} X_{ab}, \quad (2.2)$$

Di mana p_{ij} merupakan nilai keluaran pada posisi (ij) , X_{ab} menyatakan elemen-elemen dalam jendela *pooling*, dan $\mathcal{N}_{ij}$ menunjukkan area atau lingkungan yang dicakup oleh *kernel pooling*.

Melalui mekanisme ini, lapisan *pooling* mampu mempertahankan fitur yang paling dominan pada setiap wilayah sekaligus mengurangi resolusi peta fitur. Hal tersebut menjadikan jaringan saraf lebih efisien serta lebih stabil dalam menghadapi pergeseran atau perubahan kecil pada posisi objek dalam citra (Zhao & Zhang, 2024).

2.2.4. Fully Connected Layer

Lapisan *Fully Connected* (FC) berperan dalam menggabungkan fitur-fitur yang telah dipelajari oleh lapisan sebelumnya untuk menghasilkan keluaran akhir berupa prediksi atau klasifikasi. Pada lapisan ini, setiap neuron terhubung dengan seluruh neuron pada lapisan sebelumnya, sehingga membentuk struktur jaringan padat yang mampu mempelajari hubungan kompleks antar fitur (Kalaycı & Asan, 2022).

Keluaran dari lapisan *Fully Connected* dapat dinyatakan secara matematis sebagai berikut (Mienye et al., 2025):

$$Y = \sigma(W \cdot X + b), \quad (2.3)$$

di mana X merupakan vektor masukan, W adalah matriks bobot, b menyatakan vektor bias, dan σ menunjukkan fungsi aktivasi yang digunakan.


Melalui kombinasi linier antara bobot dan masukan yang diikuti oleh fungsi aktivasi, lapisan *Fully Connected* memungkinkan jaringan saraf melakukan pemetaan dari fitur tingkat tinggi ke ruang keluaran. Dengan demikian, lapisan ini memiliki peran penting dalam menentukan keputusan akhir dari model CNN berdasarkan informasi yang telah diekstraksi pada tahap sebelumnya (T. Zheng et al., 2023).

2.3. ResNet-50

ResNet-50 merupakan salah satu varian dari arsitektur *Residual Network* (ResNet) yang diperkenalkan oleh peneliti di Microsoft Research pada tahun 2015. Arsitektur ini dirancang untuk mengatasi permasalahan *degradation* dan *vanishing gradient* yang sering muncul pada jaringan saraf dalam (deep neural networks) dengan jumlah lapisan yang sangat banyak. *ResNet-50* terdiri dari 50 lapisan yang disusun menggunakan konsep *residual learning* melalui penerapan *skip connection* (Ridwan Wibisono et al., 2025).

Konsep utama *residual learning* adalah memungkinkan jaringan untuk mempelajari fungsi residual, yaitu selisih antara masukan dan keluaran suatu blok jaringan. Dengan adanya *skip connection*, keluaran suatu lapisan tidak hanya bergantung pada hasil transformasi non-linear, tetapi juga pada masukan asli yang diteruskan secara langsung ke lapisan berikutnya. Pendekatan ini mempermudah proses optimasi dan memungkinkan pelatihan jaringan yang lebih dalam secara stabil (Yasudha & Vanitha, 2025).

Secara matematis, fungsi residual pada ResNet dapat dinyatakan sebagai berikut:



Gambar 2.2 Arsitektur *ResNet50*

Sumber (Sheikh et al., 2024)

ResNet-50 menggunakan struktur *bottleneck block* yang terdiri dari tiga lapisan konvolusi, yaitu konvolusi $1 \times 1 \times 11 \times 1$ untuk reduksi dimensi, konvolusi $3 \times 3 \times 33 \times 3$ untuk ekstraksi fitur, dan konvolusi $1 \times 1 \times 11 \times 1$ untuk mengembalikan dimensi fitur. Struktur ini memungkinkan efisiensi komputasi yang lebih baik tanpa mengurangi kemampuan jaringan dalam mengekstraksi fitur yang kompleks.

Tabel 2.1. *ResNet50 network parameters*

Nama Layer	Output_size	50-Layer
Conv1	112×112	$7 \times 7, 64$, stride 2 3×3 , max Pool, stride 2
Conv2_x	56×56	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
Conv3_x	28×28	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$

Conv4_x	14×14	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$
Conv5_x	7×7	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	averagepool,fc,softmax

Sumber (Ji et al., 2024)

Arsitektur *ResNet-50* terdiri dari beberapa tahap utama yang tersusun secara bertingkat. Proses diawali oleh lapisan conv1 yang menggunakan kernel 7×7 dengan 64 *filter* dan stride 2, menghasilkan ukuran keluaran 112×112 , kemudian diikuti oleh operasi *max pooling*. Selanjutnya, jaringan memasuki rangkaian blok residual conv2_x hingga conv5_x, di mana setiap blok menggunakan struktur bottleneck yang terdiri dari tiga lapisan konvolusi berurutan berukuran 1×1 , 3×3 , dan 1×1 . Jumlah *filter* pada setiap tahap meningkat secara bertahap, yaitu 64–256 pada conv2_x, 128–512 pada conv3_x, 256–1024 pada conv4_x, dan 512–2048 pada conv5_x, sementara ukuran spasial peta fitur berkurang dari 56×56 hingga 7×7 . Setiap blok residual diulang beberapa kali sesuai dengan kedalamannya, yaitu 3 kali pada conv2_x, 4 kali pada conv3_x, 6 kali pada conv4_x, dan 3 kali pada conv5_x. Setelah seluruh proses konvolusi selesai, jaringan diakhiri dengan *average pooling*, *Fully Connected Layer*, dan softmax untuk menghasilkan keluaran klasifikasi.

Dalam praktiknya, *ResNet-50* banyak digunakan pada berbagai tugas pengolahan citra, seperti klasifikasi citra, deteksi objek, dan segmentasi citra, karena kemampuannya dalam mengekstraksi fitur tingkat tinggi secara efektif dan

stabil. Arsitektur ini juga sering dimanfaatkan sebagai model *pre-trained* dalam pendekatan *transfer learning* untuk meningkatkan kinerja model pada *Dataset* yang terbatas (Nugraha & Nurgiyatna, 2025).

2.4. Network Pruning

Teknik *pruning* merupakan salah satu metode kompresi model dalam *Deep learning* yang bertujuan untuk mengurangi kompleksitas jaringan saraf dengan menghilangkan parameter atau struktur jaringan yang dianggap tidak berkontribusi secara signifikan terhadap kinerja model (Syahputri & Hasibuan, 2024). Pada praktiknya, jaringan saraf dalam sering kali bersifat *over-parameterized*, yaitu memiliki jumlah parameter yang jauh lebih banyak dibandingkan dengan yang sebenarnya dibutuhkan untuk merepresentasikan suatu fungsi. Kondisi ini menyebabkan pemborosan sumber daya komputasi dan memori, terutama pada tahap inferensi (Cheng et al., 2024).

Secara umum, proses *pruning* dilakukan melalui evaluasi tingkat kepentingan setiap parameter dalam jaringan, kemudian bobot, neuron, kanal, atau *filter* yang dinilai kurang berpengaruh terhadap keluaran model dihapus. Hasil dari proses ini adalah jaringan saraf yang lebih ringkas dan bersifat jarang (*sparse*), namun tetap mampu mempertahankan tingkat akurasi yang mendekati model awal (Kumari et al., 2024). Oleh karena itu, penerapan *pruning* bertujuan untuk meningkatkan efisiensi komputasi, menekan kebutuhan penyimpanan, serta mempercepat waktu inferensi. Keunggulan tersebut menjadikan *pruning* sebagai teknik yang relevan untuk penerapan model *Deep learning* pada perangkat dengan keterbatasan sumber daya, seperti perangkat bergerak, sistem tertanam, dan lingkungan edge computing (Eccles et al., 2024).

Secara keseluruhan, teknik *pruning* memiliki peran penting dalam pengembangan model *Deep learning* yang lebih efisien, dengan tetap menjaga performa model pada tingkat yang kompetitif, serta mendukung implementasi model pada lingkungan dengan keterbatasan sumber daya.

2.4.1. Klasifikasi Teknik *Pruning*

Secara garis besar, teknik pemangkasan pada jaringan saraf diklasifikasikan berdasarkan tingkat granularitasnya, yaitu *Unstructured Pruning* dan *Structured Pruning* (Roth et al., 2024).

1. *Unstructured pruning*: Merupakan teknik pemangkasan tingkat halus (*fine-grained*) yang menghilangkan bobot koneksi individual (*weights*) secara spesifik berdasarkan tingkat kepentingannya, tanpa memedulikan struktur arsitektur secara keseluruhan. Metode ini mampu menghasilkan model dengan tingkat akurasi dan sparsitas yang sangat tinggi, meskipun struktur matriks yang dihasilkan menjadi tidak teratur (*sparse matrix*) (Zhang, 2025).
2. *Structured pruning*: Merupakan teknik pemangkasan yang menghilangkan unit struktural secara utuh, seperti keseluruhan kanal filter (*channels*) pada lapisan konvolusi. Pendekatan ini lebih ramah terhadap implementasi perangkat keras karena langsung mereduksi dimensi matriks, sehingga memberikan peningkatan kecepatan komputasi secara praktis dan signifikan (Li et al., 2025).

Adapun berdasarkan waktu pelaksanaannya, *pruning* dapat dilakukan sebelum pelatihan (*at initialization*), selama pelatihan (*during training*), maupun setelah pelatihan (*after training*). Penelitian ini mengadopsi pendekatan konvensional *pruning after training*, di mana pemangkasan

dilakukan setelah model *baseline* selesai dilatih, yang kemudian diikuti dengan tahap *fine-tuning* untuk memulihkan kinerja model (Zhu et al., 2025).

2.4.2. Kriteria *Pruning*

Kriteria *pruning* berfungsi untuk menentukan metrik evaluasi parameter mana yang layak untuk dihapus. Terdapat beberapa variasi kriteria yang umum diteliti, seperti *gradient-based pruning* (menggunakan turunan fungsi kerugian), *activation-based pruning* (mengevaluasi seberapa sering neuron aktif), hingga *regularization-based pruning* (memberikan penalti saat pelatihan) (Yu et al., 2025; (Ganguli & Chong, 2024).

Namun demikian, kriteria yang dinilai paling efisien, lugas, dan populer digunakan adalah *Magnitude-based pruning*. Metode ini menilai tingkat kepentingan bobot murni berdasarkan nilai absolut atau magnitudonya (Yefanov1 & N. Shapoval2, 2025). Parameter dengan nilai magnitudo yang sangat kecil (mendekati nol) dianggap memiliki kontribusi minimal terhadap hasil ekstraksi fitur keluaran model, sehingga aman untuk dipangkas. Penelitian ini secara khusus berfokus pada implementasi kriteria *magnitude-based* tersebut.

2.4.3. Magnitude-Based Pruning (*L1-Norm – L2-Norm*)

Pada penelitian ini, seleksi parameter dan filter yang akan dipangkas dilakukan secara komprehensif menggunakan dua metrik pengukuran magnitudo, yaitu *L1-Norm* untuk *Unstructured Pruning* dan *L2-Norm* untuk *Structured Pruning*.

a. L1-Norm (Unstructured Pruning)

L1-Norm (atau jarak Manhattan) digunakan untuk mengevaluasi tingkat kepentingan bobot koneksi secara individual. Metode ini menghitung jumlah nilai mutlak dari seluruh elemen bobot. Semakin kecil nilainya, semakin tidak penting bobot tersebut bagi jaringan. Persamaan matematis untuk L1-Norm pada sebuah parameter didefinisikan sebagai berikut (Shaikh et al., 2024):

$$\|W\|_1 = \sum_{j=1}^M |w_j| \quad (2.4)$$

keterangan :

$\|W\|_1$: adalah nilai kepentingan *filter*

w_j : adalah elemen bobot individu dalam *filter*

M : adalah total jumlah elemen dalam *filter* tersebut

Semakin kecil nilai $\|W\|$ semakin dianggap tidak penting *filter* tersebut dalam jaringan.

b. L2-Norm (Structured Pruning)

L2-Norm (atau jarak *Euclidean*) digunakan untuk mengevaluasi tingkat kepentingan sebuah filter atau saluran (*channel*) secara keseluruhan. Berbeda dengan L1-Norm yang hanya menjumlahkan nilai absolut, L2-Norm menghitung akar kuadrat dari jumlah kuadrat seluruh bobot di dalam satu filter utuh. Persamaan matematis untuk L2-Norm didefinisikan sebagai berikut (Chen et al., 2023):

$$\|F\|_2 = \sqrt{\sum_{j=1}^m (w_j)^2} \quad (2.4)$$

keterangan :

$\|F\|_2$: Nilai magnitudo L2-Norm untuk sebuah filter

w_j : Elemen bobot individual ke- j di dalam filter tersebut

M : Total jumlah elemen bobot dalam satu filter

2.5. Pengoptimasi (*Optimizer*)

Optimizer merupakan komponen penting dalam proses pelatihan model *deep learning* yang berperan dalam meminimalkan nilai fungsi kerugian (*loss function*) melalui pembaruan parameter jaringan saraf secara iteratif berdasarkan gradien. Proses optimasi ini umumnya dilakukan menggunakan pendekatan *gradient-based optimization*, di mana bobot model disesuaikan untuk mencapai konvergensi yang optimal. Pada jaringan saraf dalam dengan jumlah parameter yang besar, pemilihan *Optimizer* menjadi krusial karena secara langsung memengaruhi stabilitas pelatihan, kecepatan konvergensi, serta kualitas solusi akhir yang dihasilkan oleh model (Guo, 2024).

Pada penelitian ini digunakan *Optimizer* ADAM (*Adaptive Moment Estimation*) karena kemampuannya dalam mengombinasikan keunggulan metode *momentum* dan *adaptive learning rate*. ADAM secara adaptif menyesuaikan laju pembelajaran untuk setiap parameter dengan memanfaatkan estimasi momen pertama dan kedua dari gradien, sehingga mampu mengatasi fluktuasi gradien dan mempercepat konvergensi (Reyad et al., 2023). Keunggulan ini menjadikan ADAM sangat efektif dalam melatih model *deep learning* dengan distribusi gradien yang tidak stabil dan data terbatas. Sejumlah penelitian menunjukkan bahwa penggunaan ADAM mampu menurunkan *error rate* serta meningkatkan stabilitas dan efisiensi pelatihan dibandingkan metode optimasi konvensional. Oleh karena itu, ADAM dipilih untuk melatih model CNN kompleks seperti *ResNet-50* karena mampu

memberikan proses pelatihan yang lebih stabil, efisien, dan konsisten (Fatma et al., 2025).

Secara matematis, mekanisme kerja *Optimizer* ADAM dapat dirumuskan sebagai berikut. Gradien fungsi kerugian terhadap parameter pada iterasi ke $-t$ dihitung dengan:

$$g_t = \nabla_{\theta} L(\theta_t) \quad (2.5)$$

Selanjutnya, ADAM menghitung estimasi momen pertama dan momen kedua dari gradien (Jeong & Koo, 2024):

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (2.6)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (2.7)$$

Untuk mengatasi bias pada iterasi awal, dilakukan *bias correction* sebagai berikut (Jeong & Koo, 2024) :

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (2.8)$$

Parameter model kemudian diperbarui menggunakan persamaan (Jeong & Koo, 2024) :

$$\theta_{t+1} = \theta_t - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (2.9)$$

keterangan :

- θ_t : parameter model pada iterasi ke $-t$
- $L(\theta)$: fungsi kerugian
- g_t : gradien fungsi kerugian
- m_t : estimasi momen pertama
- v_t : estimasi momen kedua
- β_1, β_2 : koefisien peluruhan (umumnya 0,9 dan 0,999)
- η : learning rate

ϵ : konstanta kecil untuk menjaga stabilitas numerik

2.6. Metode Evaluasi

Evaluasi merupakan tahap akhir yang dilakukan untuk mengukur kinerja model dalam mendeteksi penyakit daun jagung. Salah satu metode yang umum digunakan dalam evaluasi model klasifikasi adalah dengan menghitung nilai-nilai yang dihasilkan dari *Confusion Matrix*. *Confusion Matrix* memberikan informasi mengenai perbandingan antara hasil prediksi model dan label aktual, sehingga memungkinkan analisis kesalahan klasifikasi secara lebih terperinci (Sathyanarayanan, 2024).

Kinerja model klasifikasi dapat dievaluasi menggunakan beberapa metrik, antara lain *Accuracy*, *Precision*, *recall*, dan *F1-score*. Metrik-metrik tersebut memberikan gambaran yang jelas mengenai kemampuan model dalam mengklasifikasikan penyakit daun jagung secara benar dan konsisten. Berikut ini adalah rumus-rumus yang digunakan untuk mengukur kinerja model klasifikasi.

Tabel 2.2. *Confusion Matrix*

Actual	Prediced	
	Positive (1)	Negative (0)
Positive (1)	TP	FP
Negative (0)	FN	FN

a. *Accuracy*

Mengukur presentase prediksi yang benar dari seluruh prediksi (Vo et al., 2025).

$$Accuracy = \frac{TP + TN}{Tp + TN + FP + FN} \quad (2.10)$$

b. *Precision*

Mengukur seberapa tepat model dalam mendeteksi kelas *positif*, yaitu jumlah prediksi benar *positif* dibandingkan dengan semua prediksi (Vo et al., 2025).

$$Precision = \frac{TP}{TP + FP} \quad (2.11)$$

c. *Recall*

Mengukur kemampuan model dalam menemukan semua kasus *positif* dari *Dataset* (Vo et al., 2025).

$$Recall = \frac{TP}{TP + FN} \quad (2.12)$$

d. *F1-Score*

Rata-rata harmonic dari *Precision* dan *recall*, cocok ketika ada ketidakseimbangan kelas (Vo et al., 2025).

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.13)$$

e. Ukuran Model (*Model Size*)

Selain metrik performa klasifikasi, efisiensi arsitektur diukur melalui ukuran model (*model size*). Ukuran model dihitung berdasarkan jumlah total parameter (bobot dan bias) yang memiliki nilai selain nol (*non-zero parameters*) dikalikan dengan alokasi memori dari tipe data yang digunakan (misalnya tipe *Float32* memakan 4 byte per parameter).

$$Ukuran Model (Byte) = Total Parameter \times 4 Byte \quad (2.14)$$

Hasil dari perhitungan ini kemudian dikonversi ke dalam satuan Megabyte (MB) untuk merepresentasikan ukuran fisik *file* model (ekstensi .pth) pada media penyimpanan.

Keterangan :

TP (*True Positive*) : *Dataset* daun jagung yang diprediksi dengan benar

TN (*True Negative*) : *Dataset* jagung sehat / kelas lain yang diprediksi dengan benar

FP (*False Positive*) : *Dataset* daun jagung sehat yang salah diprediksi sebagai penyakit

FN (*False Negative*) : *Dataset* daun jagung yang salah diprediksi sebagai sehat

2.7. Penelitian Terdahulu

Berikut merupakan penelitian yang pernah dilakukan sebelumnya terkait metode penelitian *ResNet-50* dan Metode *Pruning*.

Tabel 2.3. Penelitian Terdahulu

No	Penulis	Metode	Keterangan
1	(Ishak et al., 2024)	<i>ResNet50</i>	<i>ResNet-50</i> digunakan untuk mengenali perilaku mengemudi pada kondisi malam hari dengan menerapkan <i>Contrast Limited Adaptive Histogram Equalization</i> (CLAHE) pada citra berintensitas rendah, sehingga meningkatkan ketahanan model terhadap kondisi minim cahaya, dengan akurasi tertinggi sebesar 90,73%.

No	Penulis	Metode	Keterangan
2	(Sitompu l et al., 2024)	<i>ResNet50</i>	<i>ResNet-50</i> digunakan untuk mengklasifikasikan cacat kain melalui pendekatan <i>transfer learning</i> pada platform <i>FastAI</i> , dengan lima kelas citra kain, dan menghasilkan akurasi rata-rata sebesar 92,5% pada model dua kelas serta 70,3% pada model lima kelas.
3	(Vo et al., 2025)	<i>ResNet50</i>	<i>ResNet-50</i> digunakan sebagai bagian dari model klasifikasi penyakit daun anggur dengan pendekatan <i>bilinear pooling</i> bersama model <i>Xception</i> untuk mengekstraksi dan menggabungkan fitur, sehingga mampu meningkatkan akurasi identifikasi penyakit daun anggur secara efektif.
4	(Salma et al., 2025)	<i>ResNet50</i>	Pada penelitian klasifikasi daging unggas, <i>ResNet50</i> menunjukkan kinerja yang baik dengan mencapai akurasi sebesar 91%, yang mencerminkan kemampuannya dalam mengekstraksi fitur citra yang kompleks secara hierarkis. Namun, kedalaman arsitektur <i>ResNet50</i> menyebabkan


No	Penulis	Metode	Keterangan
			tingginya kompleksitas komputasi dan kebutuhan sumber daya, sehingga penerapannya menjadi kurang efisien pada lingkungan dengan keterbatasan perangkat.
5	(Kasturi et al., 2024)	<i>ResNet50</i>	<i>ResNet-50</i> sebagai model ekstraksi fitur citra dalam system klasifikasi fitur visual dari <i>ResNet 50</i> dikombinasikan dengan pemodelan teks menggunakan LSTM dan mekanisme attention, mencapai akurasi hingga 90,31%
6	(Yang, et al., 2023)	Structured Pruning berbasis <i>rank feature map</i>	Penelitian ini mengusulkan metode pruning untuk mengompresi model ResNet dengan mengidentifikasi lapisan sensitif dan tidak sensitif. Hasil eksperimen menunjukkan pengurangan FLOPs hingga 53,8% dan parameter hingga 39,9% pada <i>ResNet-50</i> dengan penurunan akurasi yang rendah.
7	(Ghimire et al., 2023)	Structured pruning berbasis loss (LAASP)	Metode pruning yang diusulkan mampu mengurangi FLOPs hingga lebih dari 50% pada berbagai arsitektur CNN dengan penurunan akurasi yang relatif kecil.

No	Penulis	Metode	Keterangan
8	(Wenbin et al., 2023)	Progressive Differentiable Architecture Search (PDAS)	Metode PDAS melakukan pruning melalui pencarian kanal secara progresif berbasis diferensiabel untuk menyeimbangkan efisiensi komputasi dan performa model, serta mampu mengurangi FLOPs secara signifikan dengan penurunan akurasi yang sangat kecil pada berbagai arsitektur CNN.
9	(Sharma et al., 2024)	Dynamic Parameter Rank Pruning (SVD-based)	Metode ini melakukan kompresi CNN melalui reduksi rank parameter secara dinamis menggunakan SVD selama pelatihan, sehingga menghasilkan penghematan parameter yang signifikan dengan tetap menjaga atau meningkatkan performa klasifikasi.
10	(Malihi & Heidemann, 2023)	Hybrid Knowledge Distillation dan Pruning	Penelitian ini menggabungkan knowledge distillation dan network pruning untuk kompresi model CNN, sehingga menghasilkan model yang lebih ringkas dengan akurasi yang setara atau lebih baik dibandingkan model terdistilasi tanpa pruning.

BAB III METODOLOGI PENELITIAN

3.1. Diagram Alur Penelitian

Penelitian ini memiliki alur penelitian yang dimulai dengan pengumpulan data berupa citra penyakit daun jagung yang diperoleh dari platform *Kaggle*, kemudian dilakukan tahap *preprocessing* untuk menyiapkan data sebelum digunakan dalam model. Selanjutnya, *Dataset* dibagi menjadi data *training*, *validation*, dan *testing*. Model *ResNet-50* digunakan sebagai model dasar untuk melakukan klasifikasi penyakit daun jagung, kemudian diterapkan teknik *pruning* untuk mengurangi kompleksitas model. Model hasil *pruning* selanjutnya dilatih ulang dan dievaluasi menggunakan metrik akurasi, *Precision*, recall, dan *F1-Score* untuk mengukur kinerja klasifikasi. Diagram alur penelitian ini ditunjukkan pada Gambar 3.1



Gambar 3.1 Alur Penelitian

3.2. Metode Pengumpulan Data


Dataset yang digunakan dalam penelitian ini merupakan data *sekunder* berupa citra daun jagung yang diperoleh dari platform daring *Kaggle* melalui *Dataset Corn Leaf Disease*. *Kaggle* merupakan repositori *Dataset* berbasis web yang banyak digunakan dalam penelitian *machine learning*. *Dataset* ini berisi 4.000 citra RGB yang terbagi ke dalam empat kelas, yaitu *Healthy*, *Leaf Blight*, *Leaf Spot*, dan *Leaf Rust*, dengan masing-masing kelas berjumlah 1.000 citra.

Citra pada *Dataset* ini dikumpulkan dari kondisi lapangan dengan teknik pengambilan gambar yang memperhatikan pencahayaan dan latar belakang agar objek daun jagung terlihat jelas. Proses pelabelan dilakukan oleh pihak yang berkompeten dan telah tersedia secara terstruktur pada platform *Kaggle*, sehingga *Dataset* ini layak digunakan untuk penelitian klasifikasi penyakit daun jagung menggunakan pendekatan deep learning.

Contoh gambar dan jumlah data untuk keempat jenis penyakit akan ditampilkan pada gambar dan tabel berikut.

Tabel 3.1. Jumlah *Dataset*

Data Daun Sehat	1000
Data Bercak Daun	1000
Data Hawar Daun	1000
Data Karat Daun	1000
Total	4000



Gambar 3.2 Contoh Dataset Penyakit Pada Daun jagung

(a) Sehat, (b) Bercak, (c) Hawar, (d) Karat

Sumber (Noola & Basavaraju, 2022),(Mohammad, et al., 2022),(Aeri Rachmad, et al., 2022)

3.3. Pra-pemrosesan Data (*Data Preprocessing*)

Sebelum data citra dimasukkan ke dalam model *ResNet-50*, dilakukan serangkaian tahapan pra-pemrosesan untuk menyeragamkan format data dan meningkatkan keragaman data latih. Tahapan ini terdiri dari *resizing*, *Normalisasi*, dan augmentasi data.

3.3.1. Resizing dan *Normalisasi*

Citra asli dari dataset memiliki dimensi resolusi tinggi yang bervariasi karena pengambilan gambar dilakukan menggunakan perangkat kamera yang berbeda-beda. Sementara itu, arsitektur *ResNet-50* dirancang untuk menerima masukan citra dengan dimensi standar. Oleh karena itu, seluruh citra dalam dataset diubah ukurannya (*resize*) menjadi 224×224 piksel menggunakan metode interpolasi bilinear. Hal ini bertujuan untuk menyesuaikan dimensi citra dengan *Input Layer* pada model tanpa mengubah informasi visual utama pada daun jagung.


Selain penyesuaian ukuran, dilakukan proses *Normalisasi* nilai piksel. Nilai piksel yang awalnya berada pada rentang 0 hingga 255 dikonversi menjadi rentang

0 hingga 1. Selanjutnya, nilai tersebut diNormalisasi berdasarkan standar statistik *ImageNet* dengan nilai *mean* [0.485, 0.456, 0.406] dan standar deviasi [0.229, 0.224, 0.225]. Langkah ini penting untuk mempercepat konvergensi model saat proses pelatihan (*training*).

3.3.2. Augmentasi Data (*Data Augmentation*)

Untuk mencegah terjadinya overfitting dimana model menghafal data latih namun buruk dalam memprediksi data baru diterapkan teknik augmentasi data. Teknik ini dilakukan hanya pada data latih (*training set*) untuk memperkaya variasi citra secara artifisial. Beberapa teknik augmentasi yang diterapkan meliputi:

1. *Random Rotation*: Memutar citra secara acak dengan rentang sudut ± 25 derajat. Teknik ini bertujuan agar model tetap dapat mengenali penyakit meskipun posisi daun pada citra tidak tegak lurus. Area kosong yang muncul akibat rotasi diisi dengan warna hitam (*zero padding*) untuk mempertahankan dimensi citra, sebagaimana terlihat pada Gambar 3.3 (b).
2. *Horizontal Flip*: Membalik citra secara horizontal (*pencerminan*) untuk mensimulasikan sudut pandang pemotretan yang berbeda (*kiri/kanan*), seperti ditunjukkan pada Gambar 3.3 (c).
3. *Zoom Range*: Memperbesar citra secara acak (*random crop*) lalu menyesuaikan kembali ukurannya. Teknik ini bertujuan memfokuskan model pada detail tekstur penyakit daun yang lebih spesifik, sebagaimana diilustrasikan pada Gambar 3.3 (d).




Gambar 3.3 Contoh Augmentasi data

(a) Citra Asli, (b) *Random Rotation*, (c) *Horizontal Flip*, (d) *Zoom Range*

3.4. Penerapan *Pruning* Pada *ResNet-50*

Penerapan *structured pruning* pada arsitektur *ResNet-50* bertujuan untuk mengurangi kompleksitas komputasi dengan menghapus *filter* atau kanal konvolusi yang kurang berkontribusi terhadap kinerja model. *Pruning* diterapkan pada lapisan konvolusi di dalam residual block, khususnya pada Conv3_x, Conv4_x, dan Conv5_x, sementara skip connection tetap dipertahankan agar aliran informasi residual tetap terjaga. Dengan pendekatan ini, *ResNet-50* menghasilkan arsitektur yang lebih ringkas dan efisien tanpa mengurangi kemampuan ekstraksi fitur dan performa klasifikasi secara signifikan.



Gambar 3.4 Pruning Pada *ResNet50*

Gambar menunjukkan pengurangan jumlah filter pada lapisan konvolusi (Conv 1×1 dan Conv 3×3) dari model baseline menjadi model hasil pruning, sehingga menghasilkan arsitektur yang lebih ringkas dengan kompleksitas komputasi yang lebih rendah.

3.4.1. Perhitungan Manual ResNet-50

Arsitektur *ResNet-50* terdiri dari jutaan parameter yang tidak memungkinkan untuk dihitung secara manual secara keseluruhan. Oleh karena itu, perhitungan manual dalam penelitian ini disimulasikan pada satu unit terkecil yang menjadi inti dari arsitektur ini, yaitu *Residual Block*. Tujuan simulasi ini adalah untuk mendemonstrasikan mekanisme *skip connection*, yaitu proses penjumlahan *input* asli (x) dengan hasil ekstraksi fitur ($F(x)$) untuk mencegah hilangnya informasi (*vanishing gradient*).

A. Inisialisasi Input (x)

Diasumsikan terdapat sebuah matriks *input* berukuran 3×3 yang merupakan representasi piksel dari sebagian kecil citra daun jagung:

$$x = \begin{bmatrix} 2 & 1 & 0 \\ 3 & 4 & 1 \\ 0 & 2 & 5 \end{bmatrix}$$

(fokus menghitung nilai piksel pusat yaitu 4).

B. Operasi Konvolusi (W)

Input tersebut diproses melalui lapisan konvolusi menggunakan filter/kernel (K) berukuran 3×3 untuk mengekstraksi fitur. Misalkan bobot filter adalah:

$$K = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}$$

Operasi konvolusi (*Conv*) dilakukan dengan mengalikan elemen input dengan elemen kernel yang bersesuaian, lalu menjumlahkannya:

$$Conv_{pusat} = (2 \cdot 1) + (1 \cdot 0) + (0 \cdot -1) + (3 \cdot 1) + (4 \cdot 0) + (1 \cdot 1) + (0 \cdot 1) + (2 \cdot 0)$$

$$Conv_{pusat} = (2) + (0) + (0) + (3) + (0) + (-1) + (0) + (0) + (-5)$$

$$Conv_{pusat} = 5 - 6 = -1$$

Hasil konvolusi pada posisi pusat adalah **-1**.

C. Fungsi Aktivasi (ReLU)

Nilai hasil konvolusi kemudian melewati fungsi aktivasi ReLU (*Rectified Linear Unit*) untuk menghilangkan nilai negatif (non-linearitas). Rumus ReLU adalah:

$$ReLU(z) = \max(0, z)$$

Karena hasil konvolusi bernilai **-1**, maka:

$$F(x)_{pusat} = \max(0, -1) = 0$$

Jadi, nilai fitur hasil transformasi $F(x)$ adalah **0**.

D. Operasi Penjumlahan (Skip Connection)

Langkah terakhir adalah menjumlahkan hasil transformasi $F(x)$ dengan input asli x (*Element-wise Addition*). Ini adalah inti dari ResNet.

$$y = F(x) + x$$

Kita ambil nilai pusat dari masing-masing komponen:

- Nilai Input Asli $x = 4$
- Nilai Hasil Proses $F(x) = 0$

$$y_{pusat} = 0 + 4 = 4$$

Dari simulasi di atas, terlihat bahwa meskipun proses konvolusi dan aktivasi menghasilkan nilai **0** (yang berarti fitur gagal diekstraksi atau informasi hilang),

mekanisme *residual connection* berhasil mengembalikan nilai input asli (4) ke output. Hal ini membuktikan secara matematis bahwa arsitektur *ResNet* mampu mempertahankan informasi penting dari lapisan sebelumnya, sehingga memungkinkan model untuk memiliki struktur yang sangat dalam tanpa mengalami degradasi performa.

3.4.2. Perhitungan Manual *Pruning*

Berdasarkan landasan teori pada Bab 2, penelitian ini menggunakan kriteria *L1-Norm* untuk menyeleksi *filter*. Berikut adalah simulasi perhitungan manual untuk menggambarkan proses seleksi *filter* pada satu *layer* konvolusi.

- 1) Terdapat 3 *Filter* (F_1, F_2, F_3) pada sebuah *convolutional layer*.
- 2) Ukuran kernel masing-masing adalah 3×3 .
- 3) Target *pruning* adalah 33% (menghapus 1 dari 3 *filter* dengan bobot terkecil).

Langkah 1: Inisialisasi Bobot *Filter* Misalkan nilai bobot pada ketiga *filter* tersebut adalah sebagai berikut:

Filter 1 (Matriks A) :

$$\begin{bmatrix} 1 & -1 & 1 \\ 2 & 0 & -2 \\ 1 & 1 & 0 \end{bmatrix}$$

Filter 2 (Matriks B – Bobot Kecil) :

$$\begin{bmatrix} 0.1 & 0 & -0.1 \\ 0.2 & 0.1 & -0.1 \\ 0 & 0.1 & 0.1 \end{bmatrix}$$

Filter 3 (Matriks C – Bobot Besar) :

$$\begin{bmatrix} 5 & 2 & -1 \\ 0 & 3 & 1 \\ -2 & 1 & 4 \end{bmatrix}$$

Langkah 2: Perhitungan L1-Norm Hitung jumlah nilai mutlak $\sum |w_i|$ untuk setiap *filter*:

Skor 1 (F_1) :

$$|1| + |-1| + |1| + |2| + |0| + |-2| + |1| + |1| + |0| = 9$$

Skor 2 (F_2) :

$$|0.1| + |0| + |-0.1| + |0.2| + |0.1| + |-0.1| + |0| + |0.1| + |-0.1| = 0.8$$

Skor 3 (F_1) :

$$|2| + |3| + |2| + |-3| + |4| + |-1| + |-2| + |0| + |2| = 19$$

Langkah 3: Perankingan dan Pemangkasan Berdasarkan hasil perhitungan L1-Norm, urutan *filter* dari yang paling tidak penting (skor terendah) ke yang paling penting adalah:

1. **Filter 2** (Skor: 0.8) → Ranking Terendah
2. **Filter 1** (Skor: 9)
3. **Filter 3** (Skor: 19) → Ranking Tertinggi

Sesuai target pemangkasan 33%, maka *Filter 2* dihapus dari arsitektur jaringan karena memiliki nilai *L1-Norm* paling kecil (mendekati nol). Penghapusan ini diasumsikan tidak akan merusak performa model secara signifikan karena kontribusi bobotnya sangat minim terhadap hasil prediksi.

3.5. Pembagian Data

Untuk memastikan evaluasi model dilakukan secara objektif, dataset yang berjumlah 4.000 citra dibagi menjadi tiga subset utama, yaitu data latih (*training*), data validasi (*validation*), dan data uji (*testing*). Penelitian ini menerapkan proporsi pembagian **70:15:15**.

Skema pembagian ini mengacu pada praktik terbaik (*best practice*) dalam *Deep learning* yang dijelaskan oleh **Goodfellow dkk. (2016)**, yang menegaskan

perlunya memisahkan *validation set* dari *test set*. Proporsi 70% dialokasikan untuk data latih guna memaksimalkan proses pembelajaran fitur, 15% data validasi digunakan untuk memantau *overfitting* dan melakukan *tuning* selama proses *pruning*, sedangkan 15% data uji dijaga sebagai data asing (*unseen data*) untuk mengukur performa akhir model secara murni.

Rincian penggunaan setiap subset adalah sebagai berikut:

1. **Data Latih (70%):** Digunakan untuk proses pembelajaran bobot model.
2. **Data Validasi (15%):** Digunakan untuk memantau kinerja model selama pelatihan dan menyetel *hyperparameter* guna mencegah *overfitting*.
3. **Data Uji (15%):** Digunakan hanya pada tahap akhir untuk mengukur *performa* final model pada data yang belum pernah dilihat sebelumnya.

Pembagian dilakukan secara *stratified random sampling*, yang memastikan bahwa setiap kelas penyakit memiliki proporsi yang seimbang dalam setiap subset. Detail distribusi jumlah citra untuk setiap kelas disajikan pada **Tabel 3.2**.

Tabel 3.2. Pembagian Data Latih, Validasi, dan Uji

No	Kelas	Jumlah data	Data		
			<i>Training</i> 70%	<i>Testing</i> 15%	Validasi 15%
1	Daun sehat	1000	700	150	150
2	Bercak Daun	1000	700	150	150
3	Hawar Daun	1000	700	150	150
4	Karat Daun	1000	700	150	150

3.6. Hyperparameter

Parameter yang digunakan pada penelitian adalah sebagai berikut :

Tabel 3.3. *Hyperparameter*

No	Parameter	Value
1.	Epoch	20
2.	Learning Rate	0.0001
3.	Batch	32
4.	Optimizer	Adam
5.	Metode Pruning	<i>Unstructured</i> (L1-Norm) & <i>Structured</i> (L2-Norm)

- a. **Epoch:** Pelatihan dilakukan sebanyak 20 kali putaran penuh (*iteration*) untuk mencegah *overfitting* karena model menggunakan basis *pre-trained*.
- b. **Learning Rate:** Nilai kecil 0.0001 ditetapkan untuk menjaga stabilitas bobot agar fitur penting tidak rusak saat proses *fine-tuning*.
- c. **Batch Size:** Ukuran 32 citra per proses iterasi dipilih berdasarkan dua pertimbangan utama. Pertama, menyesuaikan keterbatasan memori komputasi (VRAM GPU) pada perangkat keras agar tidak terjadi *Out of Memory* (OOM) saat memproses arsitektur ResNet-50 yang berat. Kedua, secara empiris penggunaan *batch size* menengah (32) terbukti memberikan efek regularisasi atau *noise* bawaan yang lebih baik dibandingkan *batch size* besar (seperti 64 atau 128). Hal ini membantu model menemukan *flat minima* pada ruang parameter, sehingga kemampuan generalisasinya terhadap data baru menjadi jauh lebih stabil dan terhindar dari *overfitting*.

- d. **Optimizer:** Menggunakan algoritma Adam karena memiliki kemampuan adaptif yang mempercepat konvergensi model menuju akurasi optimal.
- e. **Metode Pruning:** Penelitian ini mengeksplorasi dua pendekatan pemangkasan. Pertama, *Unstructured Pruning* (berbasis L1-Norm), di mana elemen yang dipangkas adalah bobot koneksi individual (*weights*) di dalam jaringan saraf yang nilainya sangat kecil atau mendekati nol. Kedua, *Structured Pruning* (berbasis L2-Norm), di mana elemen yang dipangkas adalah satu saluran filter konvolusi (*channels*) secara utuh yang dianggap redundan.

3.7. Ruang Lingkup Pengujian

3.7.1. Perangkat Keras

Perangkat keras yang digunakan pada penelitian terdapat pada Tabel 3.4

Tabel 3.4. Tabel Perangkat Keras

No	Perangkat Keras	Keterangan
1.	<i>Device Name</i>	<i>Desktop-Gismdgr</i>
2.	<i>Processor</i>	Intel(R) Core(TM) i5-8250U CPU @ 1.60GHz
3.	<i>RAM</i>	16.0 GB
4.	<i>Hard Disk</i>	1 TB

3.7.2. Perangkat Lunak

Perangkat Lunak yang digunakan dalam penelitian terdapat pada Tabel 3.5

Tabel 3.5. Tabel Perangkat Lunak

No	Perangkat Lunak	Keterangan
1.	Sistem Operasi	<i>Windows 11 Home Single Language</i>
2.	Bahasa Pemrograman	<i>Python</i>
3.	<i>Visual Studio Code</i>	Python 3.11.9
4.	<i>Library dan Framework</i>	PyTorch (v2.0.1), Torchvision (v0.15.2), Flask (v3.1.2), Flask-SQLAlchemy (v3.1.1), Pillow (v12.1.0)

BAB V KESIMPULAN DAN SARAN

5.1. Kesimpulan

Berdasarkan hasil pengujian dan analisis komprehensif yang telah dilakukan mengenai implementasi arsitektur *Deep Learning* ResNet-50 dengan teknik *Network Pruning* untuk klasifikasi penyakit daun jagung, dapat disimpulkan bahwa Penerapan kompresi model menggunakan teknik *Network Pruning* pada arsitektur ResNet-50 untuk klasifikasi penyakit daun jagung terbukti sangat efektif dalam mereduksi beban komputasi tanpa mengorbankan kualitas ekstraksi fitur. Pemangkasan parameter yang redundan bertindak sebagai metode regularisasi alami yang berhasil menghilangkan *noise* dan menekan *overfitting*, sehingga performanya melampaui model *baseline* (98.50%). Secara spesifik, pendekatan *Unstructured Pruning* (berbasis L1-Norm) mencapai titik optimal pada skenario pemangkasan 60%, di mana model sukses mempertahankan akurasi tertinggi sebesar 99.50% sekaligus menyusutkan ukuran *file* penyimpanan secara drastis dari 83.49 MB menjadi 42.18 MB. Metode ini menjadi rekomendasi utama apabila sistem memprioritaskan efisiensi ruang dan akurasi maksimal. Di sisi lain, pendekatan *Structured Pruning* (berbasis L2-Norm) mencapai titik optimal pada skenario 50%. Meskipun akurasinya sedikit berada di bawah metode *unstructured* (99.00%), pendekatan ini sangat unggul dalam hal efisiensi waktu, mencatatkan inferensi tercepat sebesar 0.2969 detik per citra berkat pemangkasan filter secara utuh yang meringankan beban operasi perkalian matriks. Sebagai pembuktian nilai guna, model *Unstructured Pruning* 60% telah berhasil diimplementasikan ke dalam antarmuka web cerdas "JagaJagung". Berkat ukuran yang ringan dan latensi rendah,

sistem ini beroperasi dengan sangat responsif tanpa membebani memori peladen, menjadikannya alat bantu diagnosis dini yang praktis bagi petani dan penyuluh pertanian.

5.2. Saran

Meskipun penelitian ini telah memberikan hasil optimasi yang memuaskan, masih terdapat beberapa ruang pengembangan strategis untuk penelitian selanjutnya. Pertama, guna meningkatkan ketahanan (*robustness*) model terhadap kondisi lapangan yang dinamis, disarankan untuk memperbanyak variasi *dataset* citra daun jagung, mencakup variasi pencahayaan, sudut pengambilan gambar, serta latar belakang visual yang kompleks. Kedua, penelitian lanjutan dapat mengeksplorasi pendekatan hibrida (*hybrid*) dengan menggabungkan teknik *pruning* dan metode kompresi lainnya, seperti Kuantisasi (*Quantization*) dari presisi *Float32* ke *Float16* atau *INT8*, guna menekan ukuran model lebih jauh tanpa mengorbankan akurasi. Ketiga, perlu dilakukan studi komparatif untuk membandingkan efektivitas penerapan *pruning* pada ResNet-50 dengan arsitektur yang secara bawaan (*native*) didesain ringan untuk perangkat seluler, seperti MobileNetV3, EfficientNet, atau arsitektur berbasis *Vision Transformer* (ViT). Terakhir, pengembangan antarmuka sistem sangat disarankan untuk bertransisi dari platform web menuju aplikasi *mobile* terdedikasi (Android atau iOS). Sistem *mobile* yang mampu berjalan sepenuhnya secara luring (*offline*) ini akan sangat krusial dalam memastikan aksesibilitas teknologi deteksi cerdas bagi petani di area perkebunan yang tidak memiliki jangkauan sinyal internet.

5.3. Implikasi dan Dampak

1. Bukti Empiris *Over-parameterization* dan *Sparse Representation*:

Penelitian ini memberikan bukti empiris yang kuat bahwa arsitektur *Deep Learning* modern seperti ResNet-50 memiliki tingkat *over-parameterization* (redundansi parameter) yang sangat tinggi saat diterapkan pada domain klasifikasi pertanian yang spesifik. Fakta bahwa model dapat dipangkas hingga 60% tanpa mengalami penurunan akurasi (bahkan justru melonjak tajam menjadi 99.50%) mengonfirmasi validitas teori *Sparse Representation*. Hal ini membuktikan bahwa sebuah sub-jaringan yang jauh lebih ringkas (*sparse network*) sudah lebih dari cukup untuk mengekstrak dan menangkap fitur visual penyakit daun jagung secara optimal, tanpa memerlukan jutaan bobot parameter bawaan yang justru berpotensi memicu *overfitting*.

2. Implikasi Praktis (*Practical Implications*) Secara praktis, keberhasilan penelitian ini dalam mereduksi ukuran model secara drastis menjadi 42.18 MB dan mempercepat waktu inferensi hingga mencapai 0.2969 detik per citra membuka peluang besar untuk penerapan kecerdasan buatan secara lokal (*On-Device AI*) atau *Edge Computing*. Spesifikasi arsitektur yang sangat ringan ini memungkinkan aplikasi deteksi penyakit seperti "JagaJagung" untuk berjalan dengan mulus di peladen (*server*) berspesifikasi rendah, atau bahkan dapat di-*deploy* langsung ke *smartphone* petani tanpa ketergantungan penuh pada koneksi internet awan (*cloud computation*). Selain itu, ukuran *file* model (.pth) yang sangat ringkas ini juga memberikan keuntungan signifikan dalam hal efisiensi

distribusi dan penyimpanan. Hal ini akan sangat memudahkan proses pemeliharaan (*maintenance*) dan pembaruan (*update*) aplikasi di masa depan, karena sama sekali tidak membebani memori maupun *bandwidth* sistem secara berlebihan.

3. Dampak Sosial dan Ekonomi (*Social and Economic Impact*) Secara sosial dan ekonomi, penerapan sistem klasifikasi cerdas hasil optimasi pada penelitian ini diharapkan mampu memberikan kontribusi nyata bagi sektor pertanian jagung di Indonesia. Kehadiran teknologi ini memfasilitasi deteksi dini yang mandiri dan presisi, sehingga sangat membantu para petani khususnya petani pemula—untuk mengidentifikasi jenis penyakit daun secara cepat, interaktif, dan akurat layaknya seorang pakar, tanpa harus selalu menunggu kehadiran penyuluh pertanian datang ke lokasi perkebunan. Kemandirian dalam melakukan diagnosis yang tepat dan *real-time* ini pada akhirnya bermuara pada upaya krusial dalam mitigasi risiko gagal panen. Dengan informasi yang cepat, petani dapat segera mengambil tindakan pengendalian yang spesifik, seperti pemilihan jenis fungisida yang tepat sasaran. Ketepatan penanganan ini secara langsung akan meminimalkan potensi kerugian finansial petani akibat penyebaran penyakit yang masif, sekaligus berperan penting dalam menjaga stabilitas ketahanan pangan nasional.

DAFTAR PUSTAKA

- Aeri Rachmad1*, Mohammad Syarief2, Silfia Rifka3, Fifin Sonata4, Wahyudi Setiawan5, E. M. S. R. (2022). Corn Leaf Disease Classification Using Local Binary Patterns (LBP) Feature Extraction Corn Leaf Disease Classification Using Local Binary Patterns (LBP) Feature Extraction. *Conference Series PAPER*. <https://doi.org/10.1088/1742-6596/2406/1/012020>
- Akgül, İ. (2024). A Pooling Method Developed for Use in Convolutional Neural Networks. *CMES - Computer Modeling in Engineering and Sciences*, 141(1), 751–770. <https://doi.org/10.32604/cmes.2024.052549>
- An, S., Shin, J., & Kim, J. (2025). Quantization-Aware Training With Dynamic and Static Pruning. *IEEE Access*, 13(March), 57476–57484. <https://doi.org/10.1109/ACCESS.2025.3556629>
- Aston Zhang, Zachary C. Lipton, M. L. and A. J. S. (2025). *Dive into Deep Learning 1.0.3. 4*.
- Bansod, D. A., Bhandekar, P. R., & Nawkhare, P. R. (2025). Enhanced Deep Learning Approaches for Text Classification : A Comprehensive Review. *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 13(January), 2321–9653.
- Banu, S., & Meeran, U. (2025). AI-Powered Skin Lesion Diagnosis using Whale Optimization Algorithm Enhanced ResNet 50 for Cancer Prediction. *Asian Pacific Journal of Cancer Prevention*, 26, 2919–2928. <https://doi.org/10.31557/APJCP.2025.26.8.2919>
- Blalock, D., Gonzalez Ortiz, J. J., Frankle, J., & Gutttag, J. (2020). *What Is The State Of Neural Network Pruning?*
- Cheng, H., Zhang, M., & Shi, J. Q. (2024). A Survey on Deep Neural Network Pruning: Taxonomy, Comparison, Analysis, and Recommendations. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 46(12), 10558–10578. <https://doi.org/10.1109/TPAMI.2024.3447085>

- DELL, M. (2024). Deep Learning for Economists. *Journal Of Economic Literature*, 1–52.
- Eccles, B. J., Rodgers, P., Kilpatrick, P., Spence, I., & Varghese, B. (2024). DNNShifter: An efficient DNN pruning system for edge computing. *Future Generation Computer Systems*, 152, 43–54. <https://doi.org/10.1016/j.future.2023.09.025>
- Fatma, Y., Remli, M. A., Mohamad, M. S., & Al Amien, J. (2025). Deep learning-based cryptanalysis in recovering the secret key and plaintext on lightweight cryptography. *Indonesian Journal of Electrical Engineering and Computer Science*, 38(2), 1115. <https://doi.org/10.11591/ijeecs.v38.i2.pp1115-1123>
- Ganguli, T., & Chong, E. K. P. (2024). Activation-Based Pruning of Neural Networks. *Algorithms*, 17(1). <https://doi.org/10.3390/a17010048>
- Geerthana, R., Nandhini, P., & Suriyakala, R. (2021). Medicinal Plant Identification Using Deep Learning. *International Research Journal on Advance Science Hub*, 03(05), 48–53.
- Ghimire, D., Lee, K., & Kim, S. (2023). Loss-Aware Automatic Selection of Structured Pruning. *Visual Intelligence and Platform Lab, College of Information Technology, Soongsil University, Seoul, South Korea BMobility Intelligence and Computing Systems Lab, College of Information Technology, Soongsil University, Seoul, South Korea*, 25 june.
- Grandini, M., Bagli, E., & Visani, G. (2020). Metrics For Multi-Class Classification: An OverView. *A WHITE PAPER*, 1–17.
- Guo, Y. (2024). A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications. *Deep Learning for Visual Understanding*, 7 58. <https://linkinghub.elsevier.com/retrieve/pii/S0925231215017634>

- Halim, M., Noor, M., & Olalekan, A. (2025). A Survey on State-of-the-art Deep Learning Applications and Challenges. *Preprint Submitted to Engineering Applications Of Artificial Intelligence*.
- Hindarto, D. (2023). Comparison of Detection With Transfer Learning Architecture Restnet18, Restnet50, Restnet101 on Corn Leaf Disease. *Jurnal Teknologi Informasi Universitas Lambung Mangkurat (JTIULM)*, 8(2), 41–48. <https://doi.org/10.20527/jtiulm.v8i2.174>
- Iqbal, S., N. Qureshi, A., Li, J., & Mahmood, T. (2023). On the Analyses of Medical Images Using Traditional Machine Learning Techniques and Convolutional Neural Networks. In *Archives of Computational Methods in Engineering* (Vol. 30, Issue 5). Springer Netherlands. <https://doi.org/10.1007/s11831-023-09899-9>
- Ishak, M. F., Zaman, F. H. K., Mun, N. K., Abdullah, S. A. C., & Makhtar, A. K. (2024). Improving night driving behavior recognition with ResNet50. *Indonesian Journal of Electrical Engineering and Computer Science*, 33(3), 1974–1988. <https://doi.org/10.11591/ijeecs.v33.i3.pp1974-1988>
- Jeong, J. J., & Koo, G. (2024). Adaptive Learning Rate Optimizer With Loss For Classification. *Elsevier*, 2.
- Ji, Z., Bao, S., Chen, M., & Wei, L. (2024). ICS-ResNet: A Lightweight Network for Maize Leaf Disease Classification. *Agronomy*, 14(7). <https://doi.org/10.3390/agronomy14071587>
- Jiang, S., & Zavala, V. M. (2021). Convolutional neural nets in chemical engineering: Foundations, computations, and applications. *AIChE Journal*, 67(9), 1–42. <https://doi.org/10.1002/aic.17282>
- Kalaycı, T. A., & Asan, U. (2022). Improving Classification Performance of Fully Connected Layers by Fuzzy Clustering in Transformed Feature Space. *Symmetry*, 14(4). <https://doi.org/10.3390/sym14040658>

- Kasturi, N., Totad, S. G., & Ghosh, G. (2024). Leveraging multimodal deep learning for natural disaster event classification and its damage severity analysis through social media posts. *IAES International Journal of Artificial Intelligence*, 13(4), 4766–4777. <https://doi.org/10.11591/ijai.v13.i4.pp4766-4777>
- Kumari, K. A., Ahamad, S., Patil, T., Sardana, K., Muniyandy, E., & Pilli, D. (2024). Neural Network Pruning Techniques for Efficient Model Compression. *International Journal of Intelligent Systems and Applications in Engineering*, 12(15s), 565–575.
- Li, J., Zhao, Z., Gao, S., & Ran, S. (2025). SpikingDynamicMaskFormer : Enhancing Efficiency in Spiking Neural Networks with Dynamic Masking. *Electronics*, 1–20.
- Ma, C., Liu, X., Cao, Y., & Rong, J. (2025). FasterMLP efficient vision networks combining attention mechanisms and wavelet downsampling. *Scientific Reports*, 15(1), 1–14. <https://doi.org/10.1038/s41598-025-89972-4>
- Malihi, L., & Heidemann, G. (2023). Efficient and Controllable Model Compression through Sequential Knowledge Distillation and Pruning. *Big Data and Cognitive Computing Article*, 19.
- Mienye, I. D., Swart, T. G., Obaido, G., Jordan, M., & Ilono, P. (2025). Deep Convolutional Neural Networks in Medical Image Analysis: A Review. *Information (Switzerland)*, 16(3), 1–28. <https://doi.org/10.3390/info16030195>
- Mohammad, Fraiwan; Esraa, F. ;, & Natheer, K. ; (2022). Classification of Corn Diseases from Leaf Images Using Deep. *Plants*, 1–14.
- Nadhun, K. A. (2025). Optimizing ResNet50 for Medical Image Classification : A Comparative Study of Ghost Modules , Pruning , and Knowledge Distillation. *Engineering, Technology & Applied Science Research*, 15(6), 28544–28549.

- Noola, D. A., & Basavaraju, D. R. (2022). Corn leaf image classification based on machine learning techniques for accurate leaf disease detection. *International Journal of Electrical and Computer Engineering*, 12(3), 2509–2516. <https://doi.org/10.11591/ijece.v12i3.pp2509-2516>
- Nugraha, K. W., & Nurgiyatna, N. (2025). Analisis Tren Penelitian Residual Network (ResNet) melalui Systematic Literature Review dan Bibliometric Analysis. *Sainteks*, 22(2), 117–131. <https://doi.org/10.30595/sainteks.v22i2.27154>
- Pachon, C. G., Pinzon-Arenas, J. O., & Ballesteros, D. (2024). Pruning Policy for Image Classification Problems Based on Deep Learning. *Informatics*, 1–20.
- Priatna, I., Permadi, I., & Maryanto, E. (2025). Monkeypox Classification Using Convolutional Neural Networks (CNN) Pruned Residual Network-50 (ResNet-50) Architecture on Flutter Framework. 6(4), 2434–2452.
- Purwono, Ma'arif, A., Rahmانيar, W., Fathurrahman, H. I. K., Frisky, A. Z. K., & Haq, Q. M. U. (2022). Understanding of Convolutional Neural Network (CNN): A Review. *International Journal of Robotics and Control Systems*, 2(4), 739–748. <https://doi.org/10.31763/ijrcs.v2i4.888>
- Reyad, M., Sarhan, A. M., & Arafa, M. (2023). A modified Adam algorithm for deep neural network optimization. *Neural Computing and Applications*, 35(23), 17095–17112. <https://doi.org/10.1007/s00521-023-08568-z>
- Ridwan Wibisono, M., Ma'ruf Nugroho, I., Defriani, M., Informatika, T., Tinggi, S., Wastukencana, T., Cikopak, J., 53, N., Babakancikao, K., Purwakarta, K., Barat, J., & Koresponden, P. (2025). Batik Motif Classification Using CNN With Resnet-50 Architecture. *Information Systems and Technology*, 6(1), 41–59.
- Riera, M., Arnau, J. M., & González, A. (2022). DNN pruning with principal component analysis and connection importance. *Journal of Systems Architecture*, 122, 102336. <https://doi.org/10.1016/j.sysarc.2021.102336>

- Roth, W., Schindler, G., Klein, B., Peharz, R., Tschitschek, S., Fröning, H., Pernkopf, F., & Ghahramani, Z. (2024). Resource-Efficient Neural Networks for Embedded Systems. *Journal of Machine Learning Research*, 25, 1–51.
- Saleem, M. A., Senan, N., Wahid, F., Aamir, M., Samad, A., & Khan, M. (2022). Comparative Analysis of Recent Architecture of Convolutional Neural Network. *Mathematical Problems in Engineering*, 2022. <https://doi.org/10.1155/2022/7313612>
- Salma, S., Habib, M., Tannouche, A., & Ounejjar, Y. (2025). Comparative analysis of convolutional neural network architectures for poultry meat classification. *IAES International Journal of Artificial Intelligence*, 14(5), 3715–3723. <https://doi.org/10.11591/ijai.v14.i5.pp3715-3723>
- Sathyanarayanan, S. (2024). Confusion Matrix-Based Performance Evaluation Metrics. *African Journal of Biomedical Research*, 27(4), 4023–4031. <https://doi.org/10.53555/ajbr.v27i4s.4345>
- Shaikh, A. M., Zhao, Y. B., Kumar, A., Ali, M., & Kang, Y. (2024). Efficient Bayesian CNN Model Compression using Bayes by Backprop and L1-Norm Regularization. *Neural Processing Letters*, 56(2), 1–19. <https://doi.org/10.1007/s11063-024-11593-1>
- Sharma, M., Member, S., Heard, J., Saber, E., & Member, S. (2024). Convolutional Neural Network Compression via Dynamic Parameter Rank Pruning. *IEEE Access*, 15, 1–11.
- Sheikh, L. M. K., Shaikh, A., Sandupatla, A., Pudale, R., Bakare, A., & Chavan, P. M. (2024). Classification of Simple CNN Model and ResNet50. *International Journal for Research in Applied Science and Engineering Technology*, 12(4), 4606–4610. <https://doi.org/10.22214/ijraset.2024.60677>
- Sitompul, E., Setiawan, V. L., Tarigan, H. J., & Galina, M. (2024). Image classification of fabric defects using ResNet50 deep transfer learning in FastAI. *Bulletin of Electrical Engineering and Informatics*, 13(5), 3255–3267. <https://doi.org/10.11591/eei.v13i5.8218>

- Sutinah, C., Puspita, R. D., & Fitria, A. (2025). Deep learning for deep learners: Integrasi dalam perangkat ajar. *Abdimas Siliwangi*, 8(2), 466–478. <https://doi.org/10.22460/as.v8i2.27148>
- Syahputri, C. N., & Hasibuan, M. S. (2024). Optimasi Klasifikasi Decision Tree Dengan Teknik Pruning Untuk Mengurangi Overfitting. *JSiI (Jurnal Sistem Informasi)*, 11(2), 87–96. <https://doi.org/10.30656/jsii.v11i2.9161>
- Taye, M. M. (2023). Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. *Computation*, 11(3). <https://doi.org/10.3390/computation11030052>
- Tehsin, S., Kausar, S., Jameel, A., & Humayun, M. (2023). Satellite Image Categorization Using Scalable Deep Learning. *Applied Sciences*.
- Vo, H. T., Mui, K. C., & Thien, N. N. (2025). Fusing Xception and ResNet50 features for robust grape leaf disease classification. *Bulletin of Electrical Engineering and Informatics*, 14(1), 268–275. <https://doi.org/10.11591/eei.v14i1.7269>
- Wenbin Jiang, Yuhao Chen, Suyang Wen, Long Zheng, H. J. (2023). PDAS: Improving network pruning based on Progressive Differentiable Architecture Search for DNNs,. *Future Generation Computer Systems*, 146, 98–113. <https://doi.org/https://doi.org/10.1016/j.future.2023.04.011>
- Yang, Wenchuan; Yu, Haoran; Cui, Baojiang; Sui, Runqi; Gu, T. (2023). Deep neural network pruning method based on sensitive layers and reinforcement learning. *Artificial Intelligence Review*, 56(2), 1573–7462. <https://doi.org/https://doi.org/10.1007/s10462-023-10566-5>
- Yasudha, K., & Vanitha, K. (2025). A Study On Pulmonary Cancer Detection Using. *International Journal Of Progressive Research In Engineering Management And Science (IJPREAMS) (Int Peer Reviewed Journal)*, 05(4), 2583–1062.

- Yefanov¹, I., & N. Shapoval². (2025). Pruning Of Convolutional Neural Networks Using Interpretability Of Kolmogorov-Arnold Networks. *Artificial Intelligence*, 2710–1673.
- Yu, X., Xie, C., Zhao, Z., Fan, T., Xue, L., & Zhang, Z. (2025). PrunedLoRA: Robust Gradient-Based structured pruning for Low-rank Adaptation in Fine-tuning. *Intern Work at ByteDance Seed*, 4, 1–25. <http://arxiv.org/abs/2510.00192>
- Zafar, A., Aamir, M., Mohd Naw, N., Arshad, A., Riaz, S., Alruban, A., Dutta, A. K., & Almotairi, S. (2022). A Comparison of Pooling Methods for Convolutional Neural Networks. *Applied Sciences (Switzerland)*, 12(17), 1–21. <https://doi.org/10.3390/app12178643>
- Zhang, S. (2025). Review of Tiny Machine Learning Model Pruning Techniques on Resource-constrained Devices. *Applied and Computational Engineering*, 145(1), 29–36. <https://doi.org/10.54254/2755-2721/2025.21894>
- Zhao, L., & Zhang, Z. (2024). A improved pooling method for convolutional neural networks. *Scientific Reports*, 14(1), 1–22. <https://doi.org/10.1038/s41598-024-51258-6>
- Zheng, T., Li, J., Tian, H., & Wu, Q. (2023). The Process Analysis Method of SAR Target Recognition in Pre-Trained CNN Models. *Sensors*, 23(14). <https://doi.org/10.3390/s23146461>
- Zheng, W. (2024). Comparison of transfer-learning for lightweight pre-trained model on image classification. *International Conference on Signal Processing and Machine Learning*, 0, 56–63. <https://doi.org/10.54254/2755-2721/53/20241244>
- Zhu, K., Hu, F., Ding, Y., Zhou, W., & Wang, R. (2025). A comprehensive review of network pruning based on pruning granularity and pruning time perspectives. *Neurocomputing*, 626. <https://doi.org/10.1016/j.neucom.2025.129382>

PAPER NAME

RABIATUL ADAWIYAH HASIBUAN.pdf

AUTHOR

RABIATUL ADAWIYAH HASIBUAN

WORD COUNT

13686 Words

CHARACTER COUNT

88860 Characters

PAGE COUNT

83 Pages

FILE SIZE

1.5MB

SUBMISSION DATE

Apr 30, 2026 9:46 AM GMT+7

REPORT DATE

Apr 30, 2026 9:48 AM GMT+7

● 6% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

- 6% Internet database
- 2% Publications database
- Crossref database
- Crossref Posted Content database

● Excluded from Similarity Report

- Submitted Works database
- Bibliographic material
- Cited material
- Abstract
- Small Matches (Less than 15 words)



UNIVERSITAS MEDAN AREA

FAKULTAS TEKNIK

Kampus I : Jalan Kolam Nomor 1 Medan Estate / Jalan Gedung PBSI, Medan 20223
Kampus II : Jalan Sei Serayu Nomor 70 A / Jalan Setia Budi Nomor 79 B, Medan 20112 Telepon : (061) 8225602, 8201994
Fax : (061) 8226331 HP : 0811 607 259 website: www.uma.ac.id Email : univ_medanarea@uma.ac.id

Nomor : 2575/FT/01.10/X/2025

14 Oktober 2025

Lampiran :-

Hal : **Pembimbing Tugas Akhir**

Yth. Pembimbing Tugas Akhir

NURUL KHAIRINA S.Kom, M.Kom (Sebagai Pembimbing)

di Tempat

Dengan hormat, sehubungan telah dipenuhinya persyaratan untuk memperoleh Tugas Akhir dari mahasiswa atas :

Nama : RABIATUL ADAWIYAH HASIBUAN

NIM : 228160004

Jurusan : TEKNIK INFORMATIKA

Maka dengan hormat kami mengharapkan kesediaan saudara :

NURUL KHAIRINA S.Kom, M.Kom (Sebagai Pembimbing)

Adapun Tugas Akhir Skripsi berjudul :

Penerapan Metode Pruning Pada Arsitektur ResNet-50 Untuk Meningkatkan Kinerja Klasifikasi Penyakit Daun Jagung

SK Pembimbing ini berlaku selama enam bulan terhitung sejak SK ini diterbitkan. Jika proses pembimbing melebihi batas waktu yang telah ditetapkan, SK ini dapat ditinjau ulang.

Demikian kami sampaikan, atas kesediaan saudara diucapkan terima kasih.

Dekan,



Dr Eng. Supriatno.ST, MT.



UNIVERSITAS MEDAN AREA

FAKULTAS TEKNIK

Kampus I : Jalan Kolam Nomor 1 Medan Estate ☎ (061) 7360168, Medan, 20223
 Kampus II : Jalan Setiabudi Nomor 79 / Jalan Sei Serayu Nomor 70 A ☎ (061) 42402994, Medan, 20122
 Website: www.teknik.uma.ac.id E-mail: univ_medanarea@uma.ac.id

Nomor : 355/FT.6/01.10/XII/2025
 Lamp : -
 Hal : Penelitian Dan Pengambilan Data Tugas Akhir

8 Desember 2025

Yth. Wakil Rektor Bidang Mutu Sumber Daya Manusia dan Perekonomian
 Jln. Kolam No.1
 Di
 Medan

Dengan hormat, kami mohon kesediaan bapak kiranya berkenan untuk memberikan izin dan kesempatan kepada mahasiswa kami tersebut dibawah ini :

NO	N A M A	N P M	PRODI
1	Rabiatul Adawiyah Hsb.	228160004	Teknik Informatika

Untuk melaksanakan Penelitian dan Pengambilan Data Tugas Akhir di Laboratorium Komputer Program Studi Teknik Informatika Fakultas Teknik Universitas Medan Area.

Perlu kami jelaskan bahwa Pengambilan Data tersebut adalah semata-mata untuk tujuan Ilmiah dan Skripsi, yang merupakan salah satu syarat bagi mahasiswa tersebut untuk mengikuti ujian sarjana pada Fakultas Teknik Universitas Medan Area dan tidak untuk dipublikasikan, dengan judul :

Penerapan Metode Pruning pada Arsitektur ResNet50 untuk Meningkatkan Kinerja Klasifikasi Daun Jagung.

Mohon kiranya tanggal Surat Izin Pengambilan Data Tugas Akhir agar disesuaikan dengan tanggal Terbitnya Surat ini.

Atas perhatian dan kerja sama yang baik diucapkan terima kasih.

Dekan

 DR. H. Supriatno, ST, MT
 FAKULTAS TEKNIK

Tembusan :

1. Ka. BPMPP
2. Mahasiswa
3. File

cs: Dikirim dengan CamScanner

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang



SURAT KETERANGAN SELESAI PENELITIAN

Nomor : 184/UMA/B/01.7/I/2026

Yang bertanda tangan di bawah ini :

Nama : Dr. Ir. Rahmad Syah, M.Kom, IPM, ASEAN Eng, APEC Eng
 Jabatan : Wakil Rektor Bidang Mutu Sumber Daya dan Perekonomian
 NIDN : 0105058804

Dengan ini menerangkan bahwa mahasiswa yang Namanya tercantum di bawah ini :

Nama : Rabiatul Adawiyah Hasibuan
 NPM : 228160004
 Program Studi : Teknik Informatika
 Fakultas : Teknik
 Status : (Mahasiswa / ~~Dosen~~ / Peneliti)

Telah melaksanakan dan menyelesaikan riset (penelitian) di lingkungan Universitas Medan Area dengan rincian sebagai berikut:

Judul Penelitian : Penerapan Metode Pruning Pada Arsitektur *ResNet50* untuk Meningkatkan Kinerja Klasifikasi Daun Jagung
 Lokasi Penelitian : Laboratorium Komputer Program Studi Teknik Informatika Universitas Medan Area
 Hasil Penelitian : Berdasarkan penelitian ini, dapat disimpulkan bahwa Penerapan arsitektur ResNet-50 untuk klasifikasi penyakit daun jagung terbukti sangat efektif dengan tingkat akurasi *baseline* mencapai 97,17%. Optimasi melalui teknik *model pruning* sebesar 60% menjadi skenario paling unggul karena tidak hanya meningkatkan akurasi menjadi 97,33% melalui efek regularisasi, tetapi juga berhasil mereduksi ukuran penyimpanan hingga hampir 50% (42,94 MB) dan mempercepat waktu inferensi hingga 5,5 kali lipat (0,14 detik). Namun, pemangkasan parameter memiliki batas toleransi maksimal sebesar 75%, di mana melampaui angka tersebut akan menyebabkan penurunan akurasi yang signifikan akibat hilangnya informasi fitur penting.
 Waktu Pelaksanaan : Januari 2026

Berdasarkan laporan hasil riset dan verifikasi data yang kami terima, yang bersangkutan telah menyelesaikan seluruh rangkaian kegiatan penelitiannya dengan baik.

Demikian surat ini diterbitkan untuk dapat digunakan seperlunya.

Medan, 30 Januari 2026
 Wakil Rektor Bidang Mutu Sumber
 Daya dan Perekonomian,



Dr. Ir. Rahmad Syah, M.Kom,
 IPM, ASEAN Eng, APEC Eng

CS Dipindai dengan CamScanner