

**PENERAPAN METODE PRUNING PADA ARSITEKTUR
SQUEEZENET UNTUK MENINGKATKAN KINERJA
KLASIFIKASI PENYAKIT DAUN KELAPA SAWIT**

SKRIPSI

OLEH:

NUGRAHA RAHMADAN DIYANTO

228160049



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

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

Document Accepted 1/7/26

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

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

**PENERAPAN METODE PRUNING PADA ARSITEKTUR
SQUEEZENET UNTUK MENINGKATKAN KINERJA
KLASIFIKASI PENYAKIT DAUN KELAPA SAWIT**

SKRIPSI

**Diajukan sebagai Salah Satu Syarat untuk Memperoleh
Gelar Sarjana di Fakultas Teknik
Universitas Medan Area**

Oleh:

NUGRAHA RAHMADAN DIYANTO

228160049

**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 SqueezeNet untuk
Meningkatkan Kinerja Klasifikasi Penyakit Daun Kelapa Sawit

Nama : Nugraha Rahmadan Diyanto

NPM : 228160049

Fakultas : Teknik



Tanggal Lulus: 26 Februari 2026

HALAMAN PERTANYAAN

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, 26 Februari 2026



Nugraha Rahmadan Diyanto
228160049

**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 : Nugraha Rahmadan Diyanto
NPM : 228160049
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 SqueezeNet untuk Meningkatkan Kinerja Klasifikasi Penyakit Daun Kelapa Sawit.

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 Skripsi 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 : 26 Februari 2026
Yang menyatakan



(Nugraha Rahmadan Diyanto)
228160049

RIWAYAT HIDUP

Penulis bernama Nugraha Rahmadan Diyanto, dilahirkan di Medan pada tanggal 13 November 2004. Penulis merupakan anak pertama dari 3 bersaudara dari pasangan Bapak Suroto dan Ibu Supami. Penulis menempuh pendidikan formal dimulai dari SD Negeri 010222 Sei Simujur lulus tahun 2016, kemudian melanjutkan ke SMP Negeri 5 Sei Suka lulus tahun 2019, dan SMK Negeri 1 Air Putih tahun 2022. Pada tahun 2022, penulis terdaftar sebagai mahasiswa Program Studi Teknik Informatika, Fakultas Teknik, Universitas Medan Area. Selama masa perkuliahan, penulis aktif mengembangkan kompetensi akademik melalui kompetisi tingkat nasional, salah satunya sebagai Finalis pada ajang GEMASTIK (Pagelaran Mahasiswa Nasional Bidang TIK) Tahun 2025 pada Divisi 7 Karya Tulis Ilmiah TIK. Skripsi ini merupakan tugas akhir untuk memperoleh gelar Sarjana Komputer di Universitas Medan Area.



KATA PENGANTAR

Assalamu'alaikum warahmatullahi wabarakatuh. Puji syukur penulis panjatkan kehadiran Allah SWT atas segala rahmat dan karunia-Nya sehingga skripsi dengan judul "**Penerapan Metode *Pruning* pada Arsitektur *SqueezeNet* untuk Meningkatkan Kinerja Klasifikasi Penyakit Daun Kelapa Sawit**" ini dapat diselesaikan. Dalam proses penyusunan skripsi ini, penulis banyak menerima bantuan, bimbingan, dan dukungan dari berbagai pihak. Oleh karena itu, pada kesempatan ini penulis ingin mengucapkan terima kasih kepada:


1. Bapak Prof. Dr. Dadan Ramdan, M.Eng, M.Sc. Selaku Rektor Universitas Medan Area.
2. Bapak Dr. Eng. Supriatno, S.T., M.T., selaku Dekan Fakultas Teknik, Universitas Medan Area.
3. Bapak Rizki Muliono, S.Kom., M.Kom., selaku Pembanding Tugas Akhir dan Ketua Program Studi Teknik Informatika, Fakultas Teknik, Universitas Medan Area.
4. Bapak Muhathir, ST., M.Kom., selaku Dosen Pembimbing yang memberikan bimbingan, arahan, dan masukan yang sangat berharga.
5. Seluruh Dosen Teknik Informatika Universitas Medan Area, yang telah berjasa dalam membagi ilmu, pengalaman dan wawasan yang sangat luar biasa selama masa perkuliahan.
6. Abang Robby Kurniawan Sari Damanik, S.T., Sebagai IT Support Program studi Teknik Informatika, yang selalu menolong dan memberikan dukungan teknis selama penulis berkuliah.

7. Teristimewa kepada kedua orang tua tercinta, Bapak Suroto dan Ibu Supami, yang senantiasa memberikan doa tulus, kasih sayang, serta dukungan yang tak terhingga.
8. Kepada adik-adikku tersayang, Dwiki Darmawan Syaputra dan Dian JayaKusuma, yang selalu memberikan semangat, keceriaan, dan motivasi bagi penulis.
9. Warga dan petani di Desa Sei-Simujur, Kecamatan Laut Tador, Kabupaten Batu Bara yang telah memberikan izin dan bantuan selama proses pengumpulan gambar daun kelapa sawit.
10. Teman-teman mahasiswa Program Studi Teknik Informatika 2022 yang telah memberikan dukungan dalam menyelesaikan laporan skripsi ini.
11. Seluruh pihak yang tidak dapat penulis sebutkan satu per satu, yang telah memberikan bantuan dan dukungan dalam penyusunan Skripsi ini.

Penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan demi perbaikan di masa depan. Semoga skripsi ini dapat memberikan manfaat bagi pembaca serta dapat menjadi referensi dalam penelitian lebih lanjut.

Akhir kata, semoga Allah SWT senantiasa melimpahkan rahmat dan karunia-Nya kepada semua pihak yang telah membantu dalam penyusunan skripsi ini. Aamiin Ya Rabbal 'Alamin.

Medan, 26 Februari 2026



Nugraha Rahmadan Diyanto
228160049

ABSTRAK

Arsitektur *SqueezeNet* dikenal efektif dengan jumlah parameter cukup banyak namun masih dapat dioptimalkan dengan metode *pruning* adalah teknik kompresi yang dapat mengurangi parameter model secara signifikan tanpa mengorbankan akurasi. Penelitian ini bertujuan untuk menerapkan metode *pruning* berbasis *L2-Norm* pada arsitektur *SqueezeNet* dan membandingkan kinerjanya akurasi dan efisiensi dengan model *SqueezeNet default* untuk klasifikasi empat kelas penyakit daun kelapa sawit. Penelitian menggunakan 4.000 dataset *primer* dibagi menjadi data latih (70%), validasi (20%) dan uji (10%). Arsitektur *SqueezeNet* dipangkas menggunakan *pruning* terstruktur *L2-Norm* dengan distribusi seragam pada rate 10% hingga 50% kemudian dilatih ulang. Hasil menunjukkan bahwa *SqueezeNet default* mencapai akurasi 97,50% dengan 724.548 parameter. Secara signifikan, *pruning rate* 10% justru meningkatkan akurasi menjadi 99,25% tertinggi sekaligus mengurangi parameter menjadi 579.036. *Pruning* yang terlalu agresif sebesar 40% menurunkan akurasi secara drastis menjadi 93,25%. Dapat disimpulkan bahwa *pruning rate* 10% adalah yang paling optimal membuktikan bahwa metode ini tidak hanya membuat *SqueezeNet* lebih ringan tetapi juga lebih efektif. Model hasil *pruning* 10% ini sangat cocok untuk implementasi aplikasi karena lebih efisien. Penelitian selanjutnya disarankan untuk melakukan validasi menggunakan dataset yang lebih beragam dan menguji model pada perangkat edge sesungguhnya.

Kata Kunci: *Pruning, SqueezeNet, Penyakit Daun Kelapa Sawit, Klasifikasi Citra, Deep Learning.*

ABSTRACT

The SqueezeNet architecture is known to be effective but possesses a considerable number of parameters, which can be optimized using pruning a compression technique that significantly reduces model parameters without sacrificing accuracy. This research aims to apply the L2-Norm based pruning method to the SqueezeNet architecture and compare its performance (accuracy and efficiency) against the default SqueezeNet model for classifying four classes of oil palm leaf diseases. The study used a primary dataset of 4,000 images, divided into training (70%), validation (20%), and testing (10%) sets. The SqueezeNet architecture was pruned using L2-Norm structured pruning with a uniform distribution at rates from 10% to 50%, followed by fine-tuning. The results show that the default SqueezeNet achieved 97.50% accuracy with 724,548 parameters. Significantly, a 10% pruning rate actually increased the accuracy to a high of 99.25% while simultaneously reducing the parameters to 579,036. Overly aggressive pruning, such as 40%, drastically decreased accuracy to 93.25%. It is concluded that the 10% pruning rate is the most optimal, proving that this method not only makes SqueezeNet lighter but also more effective. This 10% pruned model is highly suitable for application implementation due to its enhanced efficiency. Future research is recommended to validate these findings using a more diverse dataset and to test the model on actual edge devices.

Keywords: Pruning, SqueezeNet, Oil Palm Leaf Disease, Image Classification, Deep Learning.

DAFTAR ISI

HALAMAN PENGESAHAN.....	i
HALAMAN PERTANYAAN.....	ii
RIWAYAT HIDUP.....	iv
KATA PENGANTAR.....	v
ABSTRAK.....	vi
ABSTRACT.....	viii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xi
DAFTAR GAMBAR.....	xii
DAFTAR LAMPIRAN.....	xiii
 BAB I PENDAHULUAN.....	 14
1.1. Latar Belakang.....	14
1.2. Rumusan Masalah.....	16
1.3. Batasan Masalah.....	17
1.4. Tujuan Penelitian.....	17
1.5. Manfaat Penelitian.....	18
 BAB II TINJAUAN PUSTAKA.....	 19
2.1. <i>SqueezeNet</i>	19
2.2. Metode <i>Pruning</i>	21
2.2.1. <i>Pruning</i> berbasis L2-Norm.....	21
2.2.2. Distribusi <i>Pruning</i> Seragam.....	22
2.3. Penelitian Terdahulu.....	24
 BAB III METODOLOGI PENELITIAN.....	 26
3.1. Pembuatan Rumus/Persamaan.....	26
3.2. Sumber Dan Teknik Pengumpulan Data.....	27
3.3. Pembagian Data.....	30
3.4. <i>SqueezeNet</i>	31
3.5. Metode <i>Pruning</i>	32
3.6. <i>SqueezeNet</i> dengan Metode <i>Pruning</i>	34
3.7. <i>Konfigurasi Hyperparameter</i>	35
3.8. Alat dan Bahan Penelitian.....	35
3.9. Evaluasi Model.....	36
3.9.1. Evaluasi Kinerja Pelatihan.....	36
3.9.2. Evaluasi Kinerja Klasifikasi.....	36

3.9.3.	Evaluasi Efisiensi Komputasi.....	38
BAB IV HASIL DAN PEMBAHASAN.....		40
4.1.	Hasil <i>SqueezeNet</i>	40
4.2.	Hasil Metode <i>Pruning</i> pada <i>SqueezeNet</i>	45
4.2.1.	Hasil <i>Pruning Rate</i> 10% pada <i>SqueezeNet</i>	45
4.2.2.	Hasil <i>Pruning Rate</i> 20% pada <i>SqueezeNet</i>	50
4.2.3.	Hasil <i>Pruning Rate</i> 30% pada <i>SqueezeNet</i>	55
4.2.4.	Hasil <i>Pruning Rate</i> 40% pada <i>SqueezeNet</i>	59
4.2.5.	Hasil <i>Pruning Rate</i> 50% pada <i>SqueezeNet</i>	64
4.3.	Pembahasan.....	68
4.4.	Implementasi Model.....	73
4.5.	Hitungan Manual.....	79
4.5.1.	<i>Pruning</i> berbasis L2-Norm.....	79
4.5.2.	<i>Multiply-Accumulate Operations (MACs)</i>	83
BAB V KESIMPULAN DAN SARAN.....		86
5.1.	Kesimpulan.....	86
5.2.	Saran.....	87
DAFTAR PUSTAKA.....		88
LAMPIRAN.....		92

DAFTAR TABEL

	Halaman
Tabel 2.1. Penelitian Terdahulu Tentang <i>SqueezeNet</i> dan <i>Pruning</i>	24
Tabel 2.2. Penelitian Terdahulu Klasifikasi Penyakit Daun Kelapa Sawit.....	25
Tabel 3.1. Spesifikasi Teknis Pengambilan Data.....	30
Tabel 3.2. Pembagian dataset untuk pelatihan, validasi dan pengujian.....	31
Tabel 3.3. Konfigurasi <i>Hyperparameter</i>	35
Tabel 3.4. Metrik evaluasi dan target performa model.....	38
Tabel 4.1. <i>Classification Report</i> Hasil Pengujian <i>SqueezeNet</i>	43
Tabel 4.2. Rincian Lapisan <i>SqueezeNet</i>	44
Tabel 4.3. <i>Classification Report SqueezeNet (Pruning 10%)</i>	47
Tabel 4.4. Rincian Arsitektur <i>SqueezeNet (Pruning 10%)</i>	49
Tabel 4.5. <i>Classification Report SqueezeNet (Pruning 20%)</i>	53
Tabel 4.6. Rincian Arsitektur <i>SqueezeNet (Pruning 20%)</i>	54
Tabel 4.7. <i>Classification Report SqueezeNet (Pruning 30%)</i>	57
Tabel 4.8. Rincian Arsitektur <i>SqueezeNet (Pruning 30%)</i>	58
Tabel 4.9. <i>Classification Report SqueezeNet (Pruning 40%)</i>	61
Tabel 4.10. Rincian Arsitektur <i>SqueezeNet (Pruning 40%)</i>	63
Tabel 4.11. <i>Classification Report SqueezeNet (Pruning 50%)</i>	66
Tabel 4.12. Rincian Arsitektur <i>SqueezeNet (Pruning 50%)</i>	67
Tabel 4.13. Perbandingan Kinerja Arsitektur Penelitian Ini.....	69
Tabel 4.14. Perbandingan Efisiensi Arsitektur.....	69
Tabel 4.15. Perbandingan Arsitektur Penelitian Sebelumnya dan Penelitian ini...70	
Tabel 4.16. Contoh Lapisan – Lapisan sebelum di <i>pruning 10%</i>	80
Tabel 4.17. Hasil Perhitungan L2-Norm.....	82
Tabel 4.18. Contoh Lapisan – Lapisan sesudahdi <i>pruning 10%</i>	82
Tabel 4.19. Data Referensi dari <i>Fire-1 Module</i>	84

DAFTAR GAMBAR

	Halaman
Gambar 2.1. Arsitektur <i>SqueezeNet</i>	20
Gambar 2.2. Distribusi <i>Pruning</i> Seragam.....	23
Gambar 3.1. Alur Penelitian.....	26
Gambar 3.2. Lokasi Pengumpulan Data.....	27
Gambar 3.3. Denah Lokasi.....	28
Gambar 3.4. Gambar, (a)daun sehat(<i>healthy_leaf</i>), (b)daun kuning(<i>yellow_leaf</i>), (c)daun bercak(<i>leaf_spot</i>), (d) daun busuk(<i>rotten_leaf</i>).....	29
Gambar 3.5. <i>Fire Module</i>	32
Gambar 3.6. Metode <i>Pruning</i>	33
Gambar 3.7. SqueezeNet (<i>Fire module</i>) dengan Metode <i>Pruning</i>	34
Gambar 4.1. Grafik akurasi pelatihan dan validasi <i>Squeezenet</i>	40
Gambar 4.2. Grafik <i>Loss</i> Pelatihan dan Validasi <i>Squeezenet</i>	41
Gambar 4.3. <i>Confusion Matrix</i> Hasil Pengujian <i>SqueezeNet</i>	42
Gambar 4.4. Grafik Akurasi Pelatihan dan Validasi (<i>Pruning</i> 10%).....	45
Gambar 4.5. Grafik <i>Loss</i> Pelatihan dan Validasi (<i>Pruning</i> 10%).....	46
Gambar 4.6. <i>Confusion Matrix SqueezeNet (Pruning 10%)</i>	47
Gambar 4.7. Grafik Akurasi Pelatihan dan Validasi (<i>Pruning</i> 20%).....	50
Gambar 4.8. Grafik <i>Loss</i> Pelatihan dan Validasi (<i>Pruning</i> 20%).....	51
Gambar 4.9. <i>Confusion Matrix SqueezeNet (Pruning 20%)</i>	52
Gambar 4.10. Grafik Akurasi Pelatihan dan Validasi (<i>Pruning</i> 30%).....	55
Gambar 4.11. Grafik <i>Loss</i> Pelatihan dan Validasi (<i>Pruning</i> 30%).....	56
Gambar 4.12. <i>Confusion Matrix SqueezeNet (Pruning 30%)</i>	56
Gambar 4.13. Grafik Akurasi Pelatihan dan Validasi (<i>Pruning</i> 40%).....	59
Gambar 4.14. Grafik <i>Loss</i> Pelatihan dan Validasi (<i>Pruning</i> 40%).....	60
Gambar 4.15. <i>Confusion Matrix SqueezeNet (Pruning 40%)</i>	61
Gambar 4.16. Grafik Akurasi Pelatihan dan Validasi (<i>Pruning</i> 50%).....	64
Gambar 4.17. Grafik <i>Loss</i> Pelatihan dan Validasi (<i>Pruning</i> 50%).....	65
Gambar 4.18. <i>Confusion Matrix SqueezeNet (Pruning 50%)</i>	65
Gambar 4.19. <i>ROC</i> rata – rata model penelitian ini.....	71
Gambar 4.21. Diagram Arsitektur Sistem.....	74
Gambar 4.22. Halaman Pengujian.....	75
Gambar 4.23. Halaman pengujian model sebelum memasukkan gambar.....	75
Gambar 4.24. Halaman memasukkan gambar pengujian.....	76
Gambar 4.25. Halaman proses Pengujian.....	76
Gambar 4.26. Halaman hasil Pengujian.....	77
Gambar 4.27. Halaman aplikasi mobile.....	78
Gambar 4.28. Halaman Pengujian aplikasi mobile.....	79

DAFTAR LAMPIRAN

	Halaman
1. Dokumentasi.....	92
2. Dokumentasi Aplikasi Anugrah Tani.....	93



BAB I

PENDAHULUAN

1.1. Latar Belakang

Dokumen ini Arsitektur SqueezeNet adalah Convolutional Neural Network (CNN) yang dirancang untuk menjadi lebih efisien dengan jumlah parameter jauh lebih sedikit namun tetap mempertahankan tingkat akurasi (Jagdev dkk., 2025). Arsitektur *Squeezenet* pertama kali diperkenalkan oleh Iandola dkk pada tahun 2016 dalam klasifikasi gambar (Kilci & Koklu, 2024) dan hal ini juga ditekankan dalam penelitian lain (Fadli & Muhathir, 2025). Keunikan *SqueezeNet* terletak pada blok bangunan inti disebut *Fire Module* yang terdiri dari lapisan *squeeze* untuk mengurangi jumlah parameter dan lapisan *expand* untuk mengekstraksi fitur (Yulita dkk., 2024). *Fire Module* ini menjadikan *SqueezeNet* sangat efisien sehingga cocok untuk diterapkan pada perangkat keras dengan memori terbatas dalam penelitian (Theerthagiri dkk., 2024) dan (Saritas & Koklu, 2024) .

Sejak diperkenalkan, arsitektur *SqueezeNet* yang telah dikembangkan dalam berbagai penelitian di bidang pertanian untuk klasifikasi penyakit tanaman berbasis citra. *SqueezeNet* dengan 800.000 *parameter* untuk klasifikasi penyakit daun pisang dan mencapai akurasi 90% (Zheng dkk., 2025). Dalam kasus serupa untuk penyakit daun pisang menggunakan *SqueezeNet* dengan 1.238.499 *parameter* sehingga mendapatkan hasil akurasi 97,12% (Nassor dkk., 2024). Penerapan *SqueezeNet* juga dapat menunjukkan hasil akurasi 97% untuk diagnosis penyakit daun jagung (Theerthagiri dkk., 2024). Sementara itu, beberapa penelitian menggunakan *SqueezeNet* sebagai pengekstrak fitur pada penyakit

jambu biji menghasilkan akurasi 95,6% setelah diklasifikasikan dengan *Gradient Boosting* (Kilci & Koklu, 2024). Pendekatan modifikasi dengan menyisipkan *SimAM* didalam *SqueezeNet* (1.235.496 *parameter*) untuk mendeteksi penyakit daun kopi menghasilkan akurasi akhir sebesar 84% (Fadli & Muhathir, 2025).

Meskipun arsitektur *SqueezeNet* memberikan hasil memuaskan, pengembangan lebih lanjut masih diperlukan untuk meningkatkan efisiensi dan kinerjanya. Salah satu solusi paling efektif dengan menerapkan metode *pruning*, metode ini adalah teknik kompresi yang mampu mengurangi beban komputasi (Pachon dkk., 2024) dan memangkas jumlah *parameter* secara signifikan dengan sedikit atau tanpa penurunan akurasi (Abouelmagd dkk., 2024). Dengan menyisipkan metode *pruning* didalam arsitektur *SqueezeNet* diharapkan menjadi lebih efisien dalam memproses data yang kompleks untuk mengidentifikasi penyakit daun kelapa sawit sehingga menghasilkan klasifikasi yang lebih akurat dan cepat.

Metode pruning telah diterapkan pada berbagai arsitektur dan kasus untuk menghasilkan model yang lebih efisien. Metode *pruning* seperti *Dynamic Pruning Gate (DPG)* untuk menciptakan model deteksi penyakit tanaman dengan akurasi 94% dan mampu berjalan cepat pada platform seluler (Liu dkk., 2023). Dalam kasus klasifikasi biji bunga matahari dengan menerapkan *Iterative Magnitude Pruning (IMP)* pada *ResNet18* dan berhasil mencapai akurasi 87,50% meskipun 92% parameter telah dipangkas (Jin dkk., 2022). Model *CNN* untuk deteksi penyakit jagung pada edge devices dengan hasil *model pruning* mencapai akurasi 96% dengan rasio kompresi 2,71x (Putrada dkk., 2024). Sementara itu, metode *pruning* pada model *VGG-16* untuk dataset buah kurma, bahwa dengan

memangkas 50% *parameter* untuk model masih dapat mencapai *F1-score* sebesar 85,8% (Pachon dkk., 2024). Penelitian terdahulu menunjukkan bahwa *channel pruning* pada *ResNet-18* untuk klasifikasi penyakit daun kacang dapat mencapai akurasi 97,7% sambil mengurangi ukuran *model* hingga 57,85% (Chen dkk., 2022).

Berdasarkan keunggulan arsitektur *SqueezeNet* yang ringan dan ketangguhan metode *pruning* dalam mengurangi kompleksitas model, penelitian ini akan menguji coba modifikasi dengan menyisipkan metode *pruning* didalam arsitektur *SqueezeNet* untuk klasifikasi penyakit daun kelapa sawit. Tujuannya adalah untuk menciptakan model yang lebih ringan, lebih efisien, dan tetap akurat, sehingga cocok untuk diterapkan pada perangkat dengan sumber daya terbatas. Pendekatan ini diharapkan dapat menjadi solusi praktis dan efektif dalam deteksi dini penyakit pada tanaman kelapa sawit.

1.2. Rumusan Masalah

Arsitektur *SqueezeNet* dikenal efektif tetapi masih memiliki jumlah *parameter* yang besar Oleh karena itu, diperlukan sebuah metode pruning untuk arsitektur *SqueezeNet* dan menjadikan model yang lebih ringan dan cepat tanpa mengorbankan akurasi secara signifikan untuk kasus klasifikasi penyakit daun kelapa sawit dan pertanyaan masalah penelitian sebagai berikut.

7. Bagaimana menerapkan metode *pruning* pada arsitektur *SqueezeNet* untuk meningkatkan kinerja mengklasifikasikan penyakit pada daun kelapa sawit?

8. Bagaimana perbandingan kinerja antara model *SqueezeNet default* dengan *SqueezeNet* yang telah diterapkan metode *pruning* dalam mengklasifikasikan penyakit daun kelapa sawit?

1.3. Batasan Masalah

Berdasarkan perumusan masalah maka tujuan dari penelitian ini adalah sebagai berikut:

1. Penelitian ini bertujuan untuk menerapkan metode *pruning* pada arsitektur *SqueezeNet* untuk membuat sebuah model yang efektif dan efisien dalam meningkatkan kinerja klasifikasi penyakit daun kelapa sawit.
2. Penelitian ini bertujuan untuk membandingkan kinerja model *SqueezeNet* yang telah diterapkan metode *pruning* dengan model *SqueezeNet default* dalam mengevaluasi efektivitas dan efisiensi metode yang diusulkan.

1.4. Tujuan Penelitian

Berdasarkan tujuan yang ingin dicapai, penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Bagi petani kelapa sawit, penelitian ini menjadi dasar untuk mengembangkan aplikasi berbasis web untuk mengetahui penyakit daun yang cepat dan ringan pada perangkat dengan sumber daya terbatas. Penggunaan model *SqueezeNet* dengan metode *pruning* yang efisien ini memungkinkan petani melakukan deteksi dini penyakit langsung di

lapangan, sehingga dapat membantu menekan kerugian panen dan meningkatkan produktivitas.

2. Bagi dunia akademik, penelitian ini berkontribusi menambah wawasan ilmiah mengenai penerapan metode *pruning* pada arsitektur *SqueezeNet*, khususnya terkait efektivitas dan efisiensinya dalam studi kasus klasifikasi penyakit daun kelapa sawit. Hasil perbandingan kinerja antara model *SqueezeNet* yang telah di *pruning* dengan *SqueezeNet default* dapat menjadi referensi bagi penelitian selanjutnya di bidang *deep learning* yang berfokus pada efisiensi dan efektivitas model.

1.5. Manfaat Penelitian

Agar penelitian ini lebih terarah dan fokus pada tujuan yang telah ditetapkan, maka ruang lingkupnya dibatasi sebagai berikut:

1. Data yang digunakan adalah data *primer* dengan jumlah 4.000 gambar dari hasil pengambilan di satu lokasi spesifik (Perkebunan warga, Desa Sei-Simujur) dalam rentang waktu tertentu (27 Juli – 02 Agustus 2025).
2. Metode *pruning* yang diterapkan terbatas pada satu jenis pendekatan spesifik berbasis L2-norm dengan distribusi pruning seragam dan tidak melakukan perbandingan dengan berbagai teknik metode *pruning* lainnya.


BAB II TINJAUAN PUSTAKA

SqueezeNet adalah *Convolutional Neural Network (CNN)* yang pertama kali diperkenalkan oleh Forrest N. Iandola, Song Han, Matthew W. Moskewicz, Khalid Ashraf, William J. Dally, dan Kurt Keutzer pada tahun 2016 (Fadli & Muhathir, 2025) dan tujuan menciptakan sebuah model yang memiliki tingkat akurasi setara dengan model besar seperti AlexNet (Kilci & Koklu, 2024). Namun dengan jumlah *parameter* yang jauh lebih sedikit bahkan hingga 50 kali lebih sedikit (You dkk., 2023). *SqueezeNet* bisa menjadi solusi untuk aplikasi yang dijalankan pada perangkat keras dengan sumber daya komputasi dan memori yang terbatas (Kumaratenna & Cho, 2024).

SqueezeNet dibangun berdasarkan tiga strategi desain utama. Pertama, mengganti sebagian besar *filter* konvolusi 3x3 dengan *filter* 1x1, karena *filter* 1x1 memiliki *parameter* 9 kali lebih sedikit (Nassor dkk., 2024). Kedua, mengurangi jumlah kanal masukan (*input channels*) ke filter 3x3 untuk membatasi jumlah *total parameter* (Theerthagiri dkk., 2024). Ketiga, melakukan *downsampling* pada lapisan-lapisan akhir jaringan agar lapisan-lapisan konvolusi di awal dapat

memiliki *activation maps* yang besar, yang diyakini dapat meningkatkan akurasi klasifikasi (Nassor dkk., 2024).

Inti arsitektur *SqueezeNet* adalah sebuah blok bangunan disebut *Fire Module* (Jagdev dkk., 2025). *Fire Module* terdiri dari *squeeze* dan lapisan *expand* (Jagdev dkk., 2025). Lapisan *squeeze* hanya menggunakan *filter* konvolusi 1x1 untuk mengurangi jumlah dimensi (Zheng dkk., 2025) dan kanal atau filter dari data masukan (Alonso-Fernandez dkk., 2025). *Output* dari lapisan *squeeze* ke lapisan *expand* dengan *filter* konvolusi 1x1 dan 3x3 yang bekerja secara paralel (Jagdev dkk., 2025). Kombinasi ini memungkinkan model untuk mengekstraksi fitur yang kompleks (Theerthagiri dkk., 2024) dan sambil tetap menjaga jumlah *parameter* (Jagdev dkk., 2025).



Gambar 2.1. Arsitektur *SqueezeNet*

Pada Gambar 2.1. arsitektur *SqueezeNet* dimulai dengan sebuah lapisan konvolusi tunggal diikuti oleh serangkaian *Fire Modules* (Zheng dkk., 2025) dan jumlah berjumlah 8 modul (Jagdev dkk., 2025). Lapisan *max-pooling* ditempatkan secara strategis di antara beberapa *Fire Modules* untuk mengurangi dimensi spasial (Zheng dkk., 2025). Salah satu ciri khas lainnya adalah *SqueezeNet* tidak menggunakan lapisan *fully-connected* di bagian akhirnya (Zheng dkk., 2025) dan yang secara signifikan berkontribusi pada pengurangan total *parameter model* (Reddy & Balaga, 2025). Struktur *iSqueezeNet* sebuah arsitektur telah banyak diterapkan dalam berbagai kasus klasifikasi citra (Fadli & Muhathir, 2025).

1.7. Metode *Pruning*

Pruning (pemangkasan) adalah salah satu teknik kompresi *model* yang paling populer dalam *deep learning* (Pachon dkk., 2024). Tujuan utamanya adalah untuk mengurangi kompleksitas dan ukuran model *Convolutional Neural Network* (*CNN*) dengan cara menghilangkan *parameter* (bobot) yang dianggap redundan atau tidak memberikan kontribusi signifikan terhadap performa *model* (Chen dkk., 2022) (Sellappan dkk., 2025). Dengan menghasilkan *model* yang lebih ringan dan cepat, *pruning* menjadi solusi penting untuk memungkinkan penerapan model *deep learning* pada perangkat dengan sumber daya komputasi terbatas, seperti pada skenario *edge computing* (Putrada dkk., 2024) (Alonso-Fernandez dkk., 2025).

1.7.1. *Pruning* berbasis L2-Norm

Metode *pruning* berbasis *L2-Norm* adalah untuk mengidentifikasi dan menghapus filter yang paling tidak penting dalam sebuah lapisan konvolusi. Kepentingan filter diukur menggunakan magnitudo *L2-Norm* dari semua bobot (*weights*) di dalamnya. Filter dengan *L2-Norm* terendah dianggap paling tidak berkontribusi dan akan dihapus Pada persamaan 2.1. Rumus Magnitudo *L2 - Norm*.

$$L_2(F_i) = \sqrt{\sum (w)^2} \quad (2.1)$$

Keterangan:

$L_{2(F_i)}$ = Magnitudo *L2-Norm* dari *Filter* ke-i.

W = Nilai satu bobot individu di dalam *filter* tersebut.


$\sum$ = Jumlah dari kuadrat semua bobot (w^2) di dalam satu *filter*.

Proses *pruning* umumnya diatur oleh sebuah kebijakan *pruning* yang terdiri dari dua komponen utama yaitu kriteria *pruning* dan distribusi *pruning* pada penelitian (Pachon dkk., 2024) dan penelitian (Rukuna dkk., 2025). Kriteria *pruning* adalah aturan yang digunakan untuk menentukan parameter mana yang akan dihilangkan. Sejarahnya, salah satu pendekatan fundamental adalah *Optimal Brain Damage (OBD)* menggunakan informasi turunan kedua untuk mengukur *saliency* atau tingkat kepentingan setiap bobot (Pachon dkk., 2024) . Namun, metode yang lebih umum digunakan saat ini adalah *magnitude-based pruning*, di mana *parameter* dengan nilai *magnitudo* berdasarkan *L2-norm* (Putrada dkk.,

2024) dan untuk mengukur besaran total dari sekumpulan bobot yang dianggap tidak penting dan dihilangkan (Njoku dkk., 2024).

1.7.2. Distribusi *Pruning* Seragam

Distribusi Pruning Seragam atau Uniform Pruning Distribution adalah strategi alokasi pemangkasan yang paling mendasar di mana setiap lapisan yang dapat dipangkas menerima target persentase pemangkasan yang sama (Pachon dkk., 2024).



Gambar 2.2. Distribusi *Pruning* Seragam

Pada Gambar 2.2. Distribusi *pruning* menentukan bagaimana pemangkasan didistribusikan ke seluruh lapisan jaringan bisa secara seragam (*uniform*) setelah proses pemangkasan akan dilatih kembali (Sellappan dkk., 2025). Arsitektur SqueezeNet memproses gambar daun sawit melalui serangkaian konvolusi untuk mengekstraksi fitur penting setelah akan mengklasifikasikan gambar contohnya Daun Kuning. Distribusi pruning menentukan pemangkasan diterapkan di antara lapisan mengalokasikan pruning sama rata sambil mempertahankan akurasi.

Manfaat utama dari pruning adalah pengurangan signifikan pada jumlah *parameter* dan *MACs* atau *Multiply-Accumulate Operations* secara langsung mempercepat waktu inferensi *model* (Pachon dkk., 2024). Penelitian membuktikan bahwa *pruning* seringkali mengalami penurunan akurasi atau tanpa

penurunan sama sekali. Beberapa studi menunjukkan bahwa *model* yang dipangkas memiliki kemampuan generalisasi lebih baik (Alonso-Fernandez dkk., 2025) dan mengungguli performa *model* aslinya (Jin dkk., 2022). Kemampuan inilah yang membuat *pruning* menjadi metode yang sangat menarik, termasuk pada arsitektur yang sudah efisien seperti *SqueezeNet* (Fadli & Muhathir, 2025).

1.8. Penelitian Terdahulu

Penelitian ini memiliki landasan studi terdahulu adalah pemanfaatan arsitektur *SqueezeNet* yang telah terbukti efektif untuk klasifikasi penyakit pada berbagai tanaman dan penerapan metode *pruning* sebagai teknik yang berhasil mengompresi model *deep learning*.

Tabel 2.1. Penelitian Terdahulu Tentang *SqueezeNet* dan *Pruning*

Author (Tahun)	Topik	Metode	Hasil Penelitian
(Jagdev dkk., 2025)	Klasifikasi Penyakit Daun Tomat	<i>SqueezeNet</i>	Squeeznet Akurasi sebesar 98,74%
(Nassor dkk., 2024)	Deteksi Penyakit Daun Pisang	<i>SqueezeNet</i> (dibandingkan model <i>lightweight</i> lain)	<i>SqueezeNet</i> mengungguli model <i>lightweight</i> lainnya dengan akurasi klasifikasi model sebesar 97,12%.
(Fadli & Muhathir, 2025)	Peningkatan Akurasi Deteksi Penyakit Daun Kopi	<i>SqueezeNet</i> + Modul Atensi <i>SimAM</i>	Integrasi modul <i>SimAM</i> berhasil meningkatkan akurasi klasifikasi model dari 81% menjadi 84%.
(Jin dkk., 2022)	Klasifikasi Biji Bunga Matahari	<i>Iterative Magnitude Pruning (IMP)</i> pada ResNet18	Berhasil memangkas 92% parameter, dan akurasi <i>model</i> hasil <i>pruning</i> (87,50%) sedikit lebih baik dari model aslinya.
(Putrada dkk., 2024)	Deteksi Penyakit	<i>CNN Pruning</i>	<i>Model</i> berhasil dikompresi

	Jagung untuk Edge Computing	dengan Optimasi <i>NG-Mean</i>	2,71x dengan penurunan akurasi klasifikasi model hanya 1,05%, mencapai akurasi akhir 96%.
(Liu dkk., 2023)	Deteksi Penyakit Tanaman untuk Platform Komputasi Rendah	<i>Dynamic Pruning Gate (DPG)</i>	<i>Model</i> mencapai akurasi klasifikasi model sebesar 94% dan kecepatan inferensi 17 FPS pada perangkat seluler.
(Rahman dkk., 2025)	Klasifikasi Penyakit Daun Cabai	<i>MobileNetV2</i> dengan <i>pruning</i>	Akurasi validasi terbaik sebesar 96.48%.

Berdasarkan beberapa penelitian terdahulu tentang *SqueezeNet* dan *Pruning* dan menjadi landasan utama bagi penelitian ini telah dirangkum untuk memberikan gambaran lebih terstruktur. Tabel 2.1 hasil penelitian pada penerapan arsitektur *SqueezeNet* dan efektivitas metode *pruning* dalam berbagai kasus.


Tabel 2.2. Penelitian Terdahulu Klasifikasi Penyakit Daun Kelapa Sawit

Author (Tahun)	Metode	Hasil Penelitian
(Indrawati dkk., 2023)	<i>GoogLeNet</i>	Akurasi Sebesar 0.9322
(Mandiri dkk., 2025)	<i>AlexNet</i>	Akurasi Sebesar 0.7900

Pada Tabel 2.2 Penelitian terdahulu klasifikasi penyakit daun kelapa sawit berbagai metode *Deep Learning* seperti *GoogLeNet*, *MobileNetV2* dan *AlexNet* dengan hasil penelitian berdasarkan akurasi pelatihan dan akurasi *test*.

BAB III METODOLOGI PENELITIAN

Diagram alur dari keseluruhan tahapan penelitian. Proses ini dimulai dari tahap pengumpulan dan persiapan data, dilanjutkan dengan pelatihan dan evaluasi model menggunakan arsitektur yang diusulkan, dan diakhiri dengan penerapan model yang telah dilatih ke dalam sebuah aplikasi web dan mobile.



Gambar 3.1. Alur Penelitian

Penelitian ini dilaksanakan melalui serangkaian tahapan terstruktur seperti diilustrasikan pada Gambar 3.1. Alur penelitian. Proses diawali dengan tahap pengumpulan *dataset primer* berupa gambar daun kelapa sawit yang kemudian melalui tahap pra-pemrosesan. Setelah itu, data dibagi menjadi tiga bagian yaitu 70% untuk data latih, 20% untuk data validasi dan 10% untuk data uji. Data latih selanjutnya diperkaya melalui proses augmentasi data mencakup teknik rotasi acak, *random horizontal flip* dan *color jitter* untuk meningkatkan keragaman data dan mencegah *overfitting*. Data yang telah siap kemudian digunakan untuk


melatih arsitektur diusulkan, yaitu modifikasi *SqueezeNet* dengan metode *pruning*. Proses pelatihan model ini dikonfigurasi untuk berjalan selama 50 *epoch* dengan *batch size* 32, serta menggunakan *optimizer Adam* dan *learning rate* 0.001. Setelah model selesai dilatih, tahap evaluasi model dilakukan secara menyeluruh menggunakan metrik seperti *Confusion Matrix*, *Classification Report*, dan *Learning Curve*. Tahap akhir dari alur penelitian ini adalah penerapan model yang telah dievaluasi ke dalam aplikasi berbasis *web* dan *mobile*.

1.10. Sumber Dan Teknik Pengumpulan Data

Kelapa sawit merupakan salah satu komoditas perkebunan yang menopang perekonomian, namun produktivitasnya seringkali terancam oleh serangan penyakit. Gejala awal serangan penyakit umumnya dapat diidentifikasi secara visual melalui perubahan warna dan tekstur pada daun. Deteksi dini dan akurat terhadap penyakit menjadi kunci tindakan pengendalian yang efektif guna meminimalkan kerugian panen.




Gambar 3.2. Lokasi Pengumpulan Data



Gambar 3.3. Denah Lokasi

Penelitian ini menggunakan sumber data *primer* yang dikumpulkan secara langsung dari lapangan untuk memastikan kualitas dan keaslian data. Proses pengumpulan data dilaksanakan di area perkebunan kelapa sawit milik Warga di Desa Sei-Simujur, Kecamatan Laut Tador, Kabupaten Batu Bara, Sumatera Utara dan untuk lokasinya dapat dilihat pada Gambar 3.2. untuk dokumentasi di lokasi dan Gambar 3.3. untuk denah lokasi .

Validasi untuk memastikan relevansi sampel atau identifikasi awal daun yang menunjukkan gejala penyakit dilakukan secara manual melalui observasi langsung dan konsultasi dengan para petani setempat yang berpengalaman pada lapangan pengumpulan data.



(a)



(b)



(c)



(d)

Gambar 3.4. Gambar, (a)daun sehat(*healthy_leaf*), (b)daun kuning(*yellow_leaf*), (c)daun bercak(*leaf_spot*), (d) daun busuk(*rotten_leaf*).

Penelitian ini berfokus pada identifikasi empat kondisi utama pada daun kelapa sawit yaitu daun sehat pada Gambar 3.4(a), daun kuning pada Gambar 3.4(b) sering diakibatkan oleh defisiensi nutrisi, Pada Gambar 3.4(c) untuk daun bercak umumnya disebabkan oleh infeksi jamur dan daun busuk menandakan kerusakan jaringan parah pada Gambar 3.4(d). Setiap kondisi ini memiliki karakteristik visual yang unik yang akan digunakan untuk melatih model klasifikasi.

Tabel 3.1. Spesifikasi Teknis Pengambilan Data.

Parameter	Spesifikasi
Lokasi	Perkebunan Warga, Desa Sei-Simujur, Kab. Batu Bara, Sumatera Utara
Perangkat	Kamera <i>Smartphone Samsung A16</i>
Resolusi Gambar	50 <i>Megapiksel</i> (Mode Foto Manual)
Pencahayaan	Alami (tanpa <i>flash</i>), waktu pagi atau sore hari
Jarak ke Objek	Rata-rata 14 – 18 cm
Latar Belakang	Kertas putih ukuran A4 (diletakkan manual)
Identifikasi Sampel	Konsultasi langsung dengan petani dan petugas keamanan

Pada Tabel 3.1. untuk teknik pengambilan setiap gambar memanfaatkan kamera *smartphone* dengan resolusi tinggi pada mode manual untuk menjaga konsistensi. Guna menciptakan latar belakang yang seragam dan meminimalisir gangguan visual (*noise*), selembar kertas putih diletakkan di belakang setiap helai daun yang akan difoto. Proses pengambilan gambar dilakukan pada jarak yang relatif dekat dengan objek untuk menangkap detail tekstur dan pola penyakit secara jelas. Pemotretan ini sengaja dijadwalkan pada pagi atau sore hari untuk memanfaatkan pencahayaan alami yang lembut dan menghindari bayangan keras yang dapat mengganggu kualitas citra.

1.11. Pembagian Data

pembagian data merupakan salah satu proses keseluruhan dataset dibagi menjadi tiga *subset* yaitu data latih , data validasi dan data uji (testing set). Data latih digunakan mempelajari pola dan fitur serta data validasi digunakan untuk memantau kinerja model dan melakukan penyesuaian *hyperparameter* selama

proses pelatihan sedangkan data uji digunakan untuk memberikan evaluasi yang objektif terhadap kinerja *SqueezeNet*.


Tabel 3.2. Pembagian dataset untuk pelatihan, validasi dan pengujian.

<i>Subset</i>	<i>Number of Images</i>	<i>Percentage</i>	<i>Total (4 Classes)</i>
<i>Training</i>	<i>700</i>	<i>70%</i>	<i>2,800 images</i>
<i>Validation</i>	<i>200</i>	<i>20%</i>	<i>800 images</i>
<i>Testing</i>	<i>100</i>	<i>10%</i>	<i>400 images</i>
<i>Total</i>	<i>1000</i>	<i>100%</i>	<i>4,000 images</i>

Setelah tahap pengumpulan dan pra-pemrosesan selesai, keseluruhan dataset dibagi menjadi tiga himpunan data memiliki fungsi terpisah yaitu data untuk pelatihan (*training*), validasi (*validation*) dan pengujian (*testing*). Data latih digunakan agar model dapat mempelajari pola-pola fitur dari setiap kelas penyakit. Data validasi berfungsi untuk mengevaluasi dan menyesuaikan *hyperparameter* model selama proses pelatihan. Terakhir, data uji digunakan untuk mengukur kinerja akhir model pada data yang belum pernah dilihat sebelumnya. Rincian lengkap mengenai jumlah gambar untuk setiap data disajikan pada Tabel 3.2. pembagian dataset untuk pelatihan, validasi, dan pengujian.

1.12. SqueezeNet

SqueezeNet adalah arsitektur *Convolutional Neural Network (CNN)* dan inti dari arsitektur *SqueezeNet* adalah *Fire Module* yang mempertahankan akurasi sehingga efektif dalam klasifikasi dan yang lainnya.




Gambar 3.5. *Fire Module*

Arsitektur dasar yang digunakan dalam penelitian ini adalah *SqueezeNet*, yang dipilih karena karakteristiknya yang ringan dan efisien untuk aplikasi pada perangkat dengan sumber daya terbatas. Kunci dari efisiensi arsitektur ini adalah penggunaan blok bangunan utamanya yang disebut *Fire Module*, yang bekerja dengan menekan (*squeeze*) dan memperluas (*expand*) kanal fitur untuk mengurangi jumlah *parameter* secara signifikan. Alur kerja dari *Fire Module* yang menjadi dasar model dalam penelitian ini diilustrasikan pada Gambar 3.5. untuk Struktur arsitektur *Fire Module*.

1.13. Metode *Pruning*

Metode pruning adalah teknik mengurangi ukuran dan kompleksitas komputasi sebuah jaringan saraf tiruan dengan menghilangkan parameter seperti filter atau koneksi neuron yang dianggap tidak penting atau redundan dari model

yang telah dilatih sehingga menghasilkan model yang lebih ringan dan cepat tanpa mengorbankan akurasi secara signifikan.




Gambar 3.6. Metode *Pruning*

Pada Gambar 3.6. diagram metode *pruning* digunakan dalam penelitian ini sebagai teknik kompresi untuk mengurangi jumlah parameter dan kompleksitas komputasi pada arsitektur *SqueezeNet*. Modifikasi ini diterapkan secara langsung di dalam setiap *Fire Module* merupakan blok bangunan inti dari *SqueezeNet*. Sebagaimana diilustrasikan pada gambar di bawah ini, proses pruning menargetkan *filter-filter* pada ketiga lapisan konvolusi yaitu lapisan 1×1 *Squeeze*, lapisan 1×1 *Expand*, dan lapisan 3×3 *Expand*. Dengan menghilangkan sebagian *filter* dari lapisan-lapisan ini berdasarkan kriteria tertentu, model yang dihasilkan menjadi lebih ringan dan efisien secara komputasi.

1.14. SqueezeNet dengan Metode Pruning.

Arsitektur *SqueezeNet* dimodifikasi dengan mengintegrasikan metode *pruning*. metode pruning diterapkan pada lapisan dan *Fire Module* dengan cara menghilangkan sebagian filter dan menghasilkan model yang jauh lebih ringan dan cepat secara komputasi tanpa mengurangi akurasi.



Gambar 3.7. SqueezeNet (Fire module) dengan Metode Pruning

Arsitektur yang diusulkan dalam penelitian ini adalah modifikasi dari *SqueezeNet* standar dengan menerapkan metode *filter pruning* untuk mengurangi jumlah *parameter* dan beban komputasi. Seperti yang diilustrasikan pada Gambar 3.7., modifikasi ini tidak mengubah alur kerja dasar *Fire Module*, melainkan menargetkan komponen internalnya dengan cara memangkas sebagian *filter* pada

lapisan konvolusi 1x1 *Squeeze* serta 1x1 *Expand* dan 3x3 *Expand*. Proses ini menghasilkan arsitektur yang lebih ringan dan efisien untuk penerapan pada perangkat dengan sumber daya terbatas.

1.15. Konfigurasi Hyperparameter

Konfigurasi *hyperparameter* adalah serangkaian parameter yang harus diatur sebelum pelatihan dimulai karena parameter ini mengontrol bagaimana model belajar.

Tabel 3.3. Konfigurasi *Hyperparameter*

<i>Hyperparameter</i>	<i>Value</i>
<i>Optimizer</i>	<i>Adam</i>
<i>Learning Rate</i>	<i>0.001</i>
<i>Batch Size</i>	<i>32</i>
<i>Epochs</i>	<i>50</i>

Proses pelatihan model dijalankan dengan *hyperparameter* yang telah ditentukan untuk mengoptimalkan proses pembelajaran mencakup pemilihan *optimizer*, laju pembelajaran, fungsi kerugian, serta parameter lain yang mengatur jalannya sesi pelatihan. Rincian lengkap dari konfigurasi disajikan pada Tabel 3.3. Konfigurasi *Hyperparameter*.

1.16. Alat dan Bahan Penelitian

Penelitian ini dilaksanakan menggunakan sistem operasi Linux Mint sebagai basis lingkungan pengembangan lokal. Proses pelatihan dan optimasi model SqueezeNet dilakukan pada platform cloud *Kaggle* dengan akselerasi Dual

GPU Nvidia T4x2 menggunakan pustaka *PyTorch* dan teknik pemangkasan *Torch-Pruning*. Untuk tahap implementasi sistem, model yang telah dilatih diintegrasikan ke dalam aplikasi berbasis web menggunakan kerangka kerja *Laravel 12* dan aplikasi *mobile* berbasis *Flutter 3.32*. Seluruh sistem kemudian didistribusikan (*deployed*) pada layanan *Virtual Private Server (VPS)* yang memiliki spesifikasi prosesor *2 Core*, memori *4 GB RAM*, dan penyimpanan *40 GB SSD* guna menjamin ketersediaan dan performa layanan yang stabil.

1.17. Evaluasi Model

Untuk mengukur kinerja dan efektivitas arsitektur SqueezeNet serta metode pruning yang diusulkan. Evaluasi ini dibagi menjadi evaluasi kinerja klasifikasi dan evaluasi efisiensi komputasi.

1.17.1. Evaluasi Kinerja Pelatihan

Evaluasi untuk memantau proses pelatihan model menggunakan kurva akurasi dan loss pada setiap epoch untuk data pelatihan dan data validasi. Analisis untuk mengamati laju pembelajaran model, memastikan tercapainya konvergensi (kondisi stabil) dan mendeteksi adanya potensi overfitting atau ketika performa pada data latih jauh lebih baik daripada data validasi.

1.17.2. Evaluasi Kinerja Klasifikasi.

Setelah model dilatih dan kinerjanya pada data uji atau data yang belum pernah dilihat akan dievaluasi menggunakan *Confusion Matrix* untuk memberikan

visualisasi rinci mengenai performa model pada setiap kelas. *Classification Report* akan merinci nilai Akurasi adalah persentase prediksi benar secara keseluruhan, Presisi adalah kemampuan model untuk tidak salah label, Recall adalah kemampuan model menemukan semua data positif, dan F1-Score adalah rata-rata dari Presisi dan Recall.

Untuk mengukur kinerja dan keandalan arsitektur model yang diusulkan, evaluasi kuantitatif akan dilakukan menggunakan beberapa metrik utama. Akurasi digunakan untuk mengukur tingkat ketepatan prediksi secara keseluruhan pada Persamaan (3.1). Presisi mengevaluasi keandalan prediksi positif untuk meminimalkan deteksi yang keliru (*false positive*) pada Persamaan (3.2), sedangkan *Recall* mengukur kemampuan model dalam mengidentifikasi semua kasus penyakit yang sebenarnya untuk meminimalkan kasus yang terlewatkan (*false negative*) pada Persamaan (3.3). Terakhir, *F1-Score* pada Persamaan (3.4) menyediakan skor tunggal yang menyeimbangkan *trade-off* antara Presisi dan *Recall*. Rincian target dan formula matematis untuk setiap metrik disajikan pada Tabel 3.4. Metrik evaluasi dan target performa model. Selain metrik kuantitatif tersebut, analisis juga akan dilengkapi dengan visualisasi *Confusion Matrix* untuk memeriksa kesalahan klasifikasi secara rinci dan *Learning Curve* untuk memastikan model tidak mengalami overfitting.

Tabel 3.4. Metrik evaluasi dan target performa model.

<i>Metric</i>	<i>Target</i>	<i>Formula</i>	
<i>Accuracy</i>	96-99%	$\frac{(TP + TN)}{(TP + TN + FP + FN)}$	(3.1)
<i>Precision</i>	>95% per class	$\frac{TP}{(TP + FP)}$	(3.2)
<i>Recall</i>	>95% per class	$\frac{TP}{(TP + FN)}$	(3.3)
<i>F1-Score</i>	>95% per class	$\frac{2 \times (Presisi \times Recall)}{(Presisi + Recall)}$	(3.4)

Karena penelitian ini merupakan klasifikasi multi-kelas, digunakan dua strategi agregasi untuk menghitung rata-rata metrik Presisi (3.5), *Recall* (3.6), dan *F1-Score* (3.7) di seluruh kelas:

Macro Average:

$$\text{Macro-Precision} = \left(\frac{1}{C} \right) \times \sum_{i=1}^C \text{Precision}_i \quad (3.5)$$

$$\text{Macro-Recall} = \left(\frac{1}{C} \right) \times \sum_{i=1}^C \text{Recall}_i \quad (3.6)$$

$$\text{Macro-F1} = \left(\frac{1}{C} \right) \times \sum_{i=1}^C \text{F1}_i \quad (3.7)$$

Weighted Average (3.8):

$$\text{Weighted-Precision} = \sum_{i=1}^C \left(\frac{n_i}{N} \right) \times \text{Precision}_i \quad (3.8)$$

dimana n_i = jumlah sampel kelas i , n = total sampel.

1.17.3. Evaluasi Efisiensi Komputasi

Penelitian ini menghasilkan model yang efisien, evaluasi komputasi sangat penting. Metrik berikut akan diukur dan dibandingkan adalah Parameter adalah

Jumlah total parameter atau bobot yang dapat dilatih dalam model serta semakin sedikit akan semakin ringan.

MACs atau *Multiply-Accumulate Operations* adalah Jumlah operasi komputasi yang diperlukan untuk satu kali inferensi. Ini adalah indikator utama beban komputasi model. Pada Persamaan 3.9. *MACs* untuk *weights* adalah rumus menghitung operasi *multiply-accumulate* pada bobot (*weights*) dan Persamaan 3.10. *MACs* dengan bias adalah rumus komputasi untuk menambahkan bias menggunakan *library* seperti *torchinfo* menghitungnya serta Persamaan 3.11. untuk rumus jumlah *MACs Layer* pada *Fire module 1* pada *SqueezeNet default*.

$$\text{MACs_Weights} = (C_{in} \times K^2 \times C_{out}) \times (H_{out} \times W_{out}) \quad (4.1)$$

$$\text{MACs_Bias} = C_{out} \times (H_{out} \times W_{out}) \quad (4.2)$$

$$\text{MACs_Total} = \text{MACs_Weights} + \text{MACs_Bias} \quad (4.3)$$

Keterangan :

C_{in} = Jumlah *Channel Input*,

C_{out} = Jumlah *Channel Output*,

K = Ukuran *Kernel*,

H_{out} = Tinggi *Output*,

W_{out} = Lebar *Output*.

Ukuran File adalah Ukuran fisik file model dalam MB setelah disimpan menentukan kebutuhan penyimpanan pada perangkat. Waktu Inferensi adalah Waktu rata-rata dibutuhkan model untuk membuat prediksi pada satu gambar diukur pada *GPU T4 x2*.

BAB V

KESIMPULAN DAN SARAN

Kesimpulan penelitian arsitektur *SqueezeNet default* telah terbukti efektif untuk klasifikasi penyakit daun kelapa sawit dengan perolehan akurasi sebesar 97.50% masih membutuhkan jumlah parameter yang banyak maka penelitian ini adalah bahwa penerapan metode *pruning* berbasis *L2-Norm* pada tingkat *rate* dari 10% - 50% tidak hanya berhasil mengurangi parameter tetapi juga mampu meningkatkan kinerjanya. *SqueezeNet* dengan *pruning rate* 10% sebagai yang terbaik dalam penelitian ini dan berhasil mencapai akurasi tertinggi sebesar 99.25%. Penelitian ini memberikan wawasan ketika *pruning* diterapkan terlalu agresif seperti *pruning rate* sebesar 40% terjadi penurunan performa drastis dengan akurasi sebesar 93.25% menandakan bahwa parameter parameter yang penting untuk klasifikasi penyakit daun kelapa sawit telah dihilangkan.

Manfaat penelitian ini adalah untuk membuat arsitektur *SqueezeNet* menjadi lebih efektif dan efisien. *SqueezeNet* dengan *pruning* berbasis *L2-Norm* untuk *rate* 10% dan 20% terbukti unggul karena tidak hanya lebih efektif daripada *SqueezeNet default* tetapi lebih ringan secara komputasi misalnya *pruning rate* 20% mengurangi parameter menjadi 458.236 dari 724.548 dan lebih cepat untuk waktu inferensi 2.2494 ms dari 2.8139 ms menggunakan *GPU T4 x2*. Hasil penelitian ini yang menjadikan *SqueezeNet* lebih ringan dan cepat sehingga cocok untuk diterapkan sistem *edge computing*, aplikasi berbasis web atau drone rakitan pemantau perkebunan kelapa sawit.

1.24. Saran

Penelitian terdapat beberapa perbaikan yang disarankan untuk pembelajaran selanjutnya dengan menggunakan dataset yang lebih besar dan lebih beragam yang mencakup lebih banyak variasi daun kelapa sawit, kondisi pencahayaan dan menambah jumlah kelas penyakit lain. Evaluasi komparatif dengan menerapkan metode pruning pada arsitektur *lightweight* populer lainnya seperti *MobileNet*, *ShuffleNet*, *GhostNet* dan lainnya. Penelitian selanjutnya dapat mengeksplorasi teknik *pruning* yang lain contoh pada penelitian (Rahman dkk., 2025) untuk penerapan *pruning* untuk menghilangkan jumlah layer dan evaluasi dengan melakukan konfigurasi hyperparameter berbeda – beda untuk mendapat efisiensi dan efektivitas dapat ditingkatkan dengan pruning. Pengembangan Penelitian lenih lanjut adalah melakukan implementasi dan pengujian pada perangkat *edge* sesungguhnya seperti *Raspberry Pi* ataupun *microcontroller esp32 cam* untuk mengukur latensi dan konsumsi daya di lapangan.

Penelitian memiliki keterbatasan mencakup variasi dan kuantitas dataset yang mungkin belum mewakili semua kondisi di lapangan serta pengujian inferensi yang dilakukan pada *GPU T4 x2*. Penelitian menggunakan distribusi *pruning* yang seragam (*uniform distribution*), di mana *pruning rate* misalnya 10% diterapkan sama rata pada keseluruhan arsitektur tanpa membedakan pentingnya setiap *layer* dan pengembangan penelitian selanjutnya bisa menambahkan variasi distribusi *pruning* untuk menemukan arsitektur yang ringan dan efektif.


DAFTAR PUSTAKA

- Abouelmagd, L. M., Shams, M. Y., Marie, H. S., & Hassanien, A. E. (2024). An optimized capsule neural networks for tomato leaf disease classification. *EURASIP Journal on Image and Video Processing*, 2024(1), 2. <https://doi.org/10.1186/s13640-023-00618-9>
- Alonso-Fernandez, F., Hernandez-Diaz, K., Buades Rubio, J. M., Tiwari, P., & Bigun, J. (2025). Deep network pruning: A comparative study on CNNs in face recognition. *Pattern Recognition Letters*, 189, 221–228. <https://doi.org/10.1016/j.patrec.2025.01.023>
- Chen, R., Qi, H., Liang, Y., & Yang, M. (2022). Identification of plant leaf diseases by deep learning based on channel attention and channel pruning. *Frontiers in Plant Science*, 13, 1023515. <https://doi.org/10.3389/fpls.2022.1023515>
- Fadli, MHD. F. A., & Muhathir. (2025). Improving The Accuracy Of Coffee Leaf Disease Detection Using Squeezenet And Simam. *JITE (Journal of Informatics and Telecommunication Engineering)*, 8, 21–30. <https://ojs.uma.ac.id/index.php/jite/article/view/14557/6301>
- Indrawati, A., Rahman, A., Pane, E., & Muhathir. (2023). Classification of Diseases in Oil Palm Leaves Using the GoogLeNet Model. *Baghdad Science Journal*, 20(6(Suppl.)), 2508. <https://doi.org/10.21123/bsj.2023.8547>
- Jagdev, S., Sundararaman, B., Khatri, N., Gaur, P., & Mewada, H. (2025). SqueezeNet-Based Deep Learning Framework for Accurate Tomato (*Solanum lycopersicum*) Leaf Disease Diagnosis and Classification. *International Journal of Computational Intelligence Systems*, 18(1), 229. <https://doi.org/10.1007/s44196-025-00978-2>

- Jin, X., Zhao, Y., Wu, H., & Sun, T. (2022). Sunflower seeds classification based on sparse convolutional neural networks in multi-objective scene. *Scientific Reports*, 12(1), 19890. <https://doi.org/10.1038/s41598-022-23869-4>
- Kilci, O., & Koklu, M. (2024). *Classification Of Guava Diseases Using Features Extracted From Squeezenet With Adaboost And Gradient Boosting*.
- Kumaratenna, K. P. S., & Cho, Y.-Y. (2024). Tea Leaf Disease Classification Using Artificial Intelligence (AI) Models. *Journal of Bio-Environment Control*, 33(1), 1–11. <https://doi.org/10.12791/KSBEC.2024.33.1.001>
- Liu, Y., Liu, J., Cheng, W., Chen, Z., Zhou, J., Cheng, H., & Lv, C. (2023). A High-Precision Plant Disease Detection Method Based on a Dynamic Pruning Gate Friendly to Low-Computing Platforms. *Plants*, 12(11), 2073. <https://doi.org/10.3390/plants12112073>
- Mandiri, T. P., Dharmawan, B. B., Ibn, F. S., & Untoro, M. C. (2025). Identifikasi Penyakit Pada Daun Kelapa Sawit Dengan Pendekatan CNN AlexNet. *Jurnal Informatika: Jurnal Pengembangan IT*, 10(3), 781–788. <https://doi.org/10.30591/jpit.v10i3.8456>
- Nassor, S., Mushthofa, M., & Priandana, K. (2024). Deep learning model for detection and classification of banana diseases based on leaf images. *IOP Conference Series: Earth and Environmental Science*, 1359(1), 012010. <https://doi.org/10.1088/1755-1315/1359/1/012010>
- Njoku, O., Chidera, A., George, I., & Kingsley, A. (2024). *A Comparative Study of Pruning Strategies for EfficientNet and ResNet Architectures in Search and Rescue Applications*.
- Pachon, C. G., Pinzon-Arenas, J. O., & Ballesteros, D. (2024). Pruning Policy for Image Classification Problems Based on Deep Learning. *Informatics*, 11(3), 67. <https://doi.org/10.3390/informatics11030067>

- Putrada, A. G., Dian Oktaviani, I., Nurkamal Fauzan, M., & Alamsyah, N. (2024). CNN Pruning for Edge Computing-Based Corn Disease Detection with a Novel NG-Mean Accuracy Loss Optimization. *Telematika*, 17(2), 68–83. <https://doi.org/10.35671/telematika.v17i2.2899>
- Rahman, S., Elveny, M., Ramli, M., & Dionikxon Manurung. (2025). MobileChiliNet: Convolutional neural network for chili leaves classification. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 14.
- Reddy, A. Y., & Balaga, T. R. (2025). Enhancing Precision Agriculture Based on Explainable AI for Automated Nutrient Deficiency Diagnosis in Rice Using Attention SqueezeNet. *Ingénierie Des Systèmes d'Information*, 30(1), 181–190. <https://doi.org/10.18280/isi.300115>
- Rukuna, A. L., Zambuk, F. U., Gital, A. Y., & Bello, U. M. (2025). Citrus diseases detection and classification based on efficientnet-B5. *Systems and Soft Computing*, 7, 200199. <https://doi.org/10.1016/j.sasc.2025.200199>
- Saritas, M. M., & Koklu, M. (2024). *Classification Of Cauliflower Leaf Diseases Using Features Extracted From Squeezenet With Decision Tree And Random Forest*.
- Sellappan, M. S., Dhanaraj, R. K., Krishnasamy, L., & Pamucar, D. (2025). *A Hybrid CNN and Segmentation-Based Pruned Deep Learning Approach for Precision Plant Disease Detection*. In Review. <https://doi.org/10.21203/rs.3.rs-6505515/v1>
- Theerthagiri, P., Ruby, A. U., Chandran, J. G. C., Sardar, T. H., & Shafeeq B. M., A. (2024). Deep SqueezeNet learning model for diagnosis and prediction of maize leaf diseases. *Journal of Big Data*, 11(1), 112. <https://doi.org/10.1186/s40537-024-00972-z>

- You, H., Lu, Y., & Tang, H. (2023). Plant Disease Classification and Adversarial Attack Using SimAM-EfficientNet and GP-MI-FGSM. *Sustainability*, 15(2), 1233. <https://doi.org/10.3390/su15021233>
- Yulita, I. N., Prabuwno, A. S., Ardiansyah, F., Rejito, J., Sholahuddin, A., & Rosadi, R. (2024). Pest Detection in Agricultural Farms using SqueezeNet and Multi-Layer Perceptron Model. *International Journal of Advanced Computer Science and Applications*, 15(6). <https://doi.org/10.14569/IJACSA.2024.0150680>
- Zheng, C. M., Taujuddin, N. S. A., Sari, S., Tukiran, Z., & Ghani, A. R. A. (2025). *Banana Leaf Disease Classification Using SqueezeNet, AlexNet and MobileNet. 6.*



LAMPIRAN


1. Dokumentasi





2. Dokumentasi Aplikasi Anugrah Tani





Similarity Report ID: oid:29477:135786846

PAPER NAME

NUGRAHA RAHMADAN DIYANTO_PENERAPAN METODE PRUNING PADA ARSITEKTUR _SQUEEZENET UNTUK MENINGKATKAN KINERJA KLASIFIKASI PENYAKIT..._sNwYPHfgLHw9SdDGURGZUN2OCxJL5RvQeKjw3PCq.pdf

AUTHOR

NUGRAHA RAHMADAN DIYANTO

WORD COUNT

16445 Words

CHARACTER COUNT

95533 Characters

PAGE COUNT

95 Pages

FILE SIZE

1.3MB

SUBMISSION DATE

Apr 20, 2026 7:51 AM GMT+7

REPORT DATE

Apr 20, 2026 7:53 AM GMT+7

6% Overall Similarity

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

- 5% Internet database
- 2% Publications database
- Crossref database
- Crossref Posted Content database
- 6% Submitted Works database

Excluded from Similarity Report

- 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 Serayn 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 : 2412/FT/01.10/IX/2025
Lampiran : -
Hal : Pembimbing Tugas Akhir

26 September 2025

Yth. Pembimbing Tugas Akhir
Muhathir S.T, M.Kom (Sebagai Pembimbing)
di Tempat

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

Nama : NUGRAHA RAHMADAN DIYANTO
NIM : 228160049
Jurusan : TEKNIK INFORMATIKA

Maka dengan hormat kami mengharapkan kesediaan saudara :

Muhathir S.T, M.Kom (Sebagai Pembimbing)

Adapun Tugas Akhir Skripsi berjudul :

**PENERAPAN METODE PRUNING PADA ARSITEKTUR SQUEEZENET UNTUK
MENINGKATKAN KINERJA KLASIFIKASI PENYAKIT DAUN KELAPA SAWIT**

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 : 308 /FT.6/01.10/X/2025
Lamp : -
Hal : Penelitian Dan Pengambilan Data Tugas Akhir

30 Oktober 2025

Yth. Kepala Desa Sei Simujur
Dusun IX, Kampung Sarang Elang, Desa Sei Simujur
Di
Batu Bara

Dengan hormat,
Kami mohon kesediaan Bapak/Ibu berkenan untuk memberikan izin dan kesempatan kepada mahasiswa kami tersebut dibawah ini :

NO	N A M A	N P M	PRODI
1	Nugraha Rahmadani Diyanto	228160049	Teknik Informatika

Untuk melaksanakan Penelitian dan Pengambilan Data Tugas Akhir pada perusahaan/Instansi yang Bapak/Ibu Pimpin.

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 penelitian :

Penerapan Metode *Pruning* pada Arsitektur *Squeezenet* untuk Meningkatkan Kinerja Klasifikasi Penyakit Daun Kelapa Sawit

Atas perhatian dan kerja sama yang baik diucapkan terima kasih.

Tembusan :

1. Ka. BPMPP
2. Mahasiswa
3. File

Dekan,

Dekan, Supriatno, ST, MT



**PEMERINTAH KABUPATEN BATU BARA
KECAMATAN LAUT TADOR
DESA SEI SIMUJUR**

Alamat : Jl.Inpres No.1 Dusun II

EMAIL desaseisimujur@gmail.com

Kode Pos 21657

SURAT KETERANGAN SELESAI PENELITIAN

Yang bertanda tangan dibawah ini :

Nama : **SUTIMIN**

Jabatan : Kepala Desa Sei Simujur

Alamat : Dusun II Inpres Desa Sei Simujur
Kecamatan Laut Tador Kabupaten Batu Bara

Dengan ini menerangkan bahwa mahasiswa yang beridentitas :

Nama : **Nugraha Rahmadan Diyanto**

NIM : 228160049

Fakultas : Teknik

Jurusan : Teknik Informatika

Universitas : Universitas Medan Area

Telah selesai melakukan penelitian di Dusun IX Kampung Sarang Elang Kecamatan Laut Tador Desa Sei Simujur Kabupaten Batu bara Provinsi Sumatra Utara, terhitung mulai tanggal 03 - 29 November 2025 untuk memperoleh data daun kelapa sawit dalam rangka penyusunan skripsi yang berjudul:

PENERAPAN METODE *PRUNING* PADA ARSITEKTUR *SQUEEZENET* UNTUK MENINGKATKAN KINERJA KLASIFIKASI PENYAKIT DAUN KELAPA SAWIT

Demikian surat keterangan ini dibuat dan diberikan kepada yang bersangkutan untuk dipergunakan seperlunya.



Sei Simujur, 01 Desember 2025

KEPALA DESA SEI SIMUJUR

SUTIMIN