

**OPTIMALISASI DETEKSI DINI PENYAKIT *GANODERMA* PADA KELAPA
SAWIT: PERBANDINGAN PENGGUNAAN INDEKS VEGETASI BERBASIS
RGB SEBAGAI INPUT METODE *CONVOLUTIONAL AUTOENCODER***

TUGAS AKHIR



VASSILISSA AMORYSDEO

NIM : 312110016

PROGRAM STUDI TEKNIK INFORMATIKA

FAKULTAS TEKNOLOGI DAN DESAIN

UNIVERSITAS MA CHUNG

MALANG

2025

LEMBAR PENGESAHAN
TUGAS AKHIR

**OPTIMALISASI DETEKSI DINI PENYAKIT *GANODERMA* PADA KELAPA
SAWIT: PERBANDINGAN PENGGUNAAN INDEKS VEGETASI BERBASIS
RGB SEBAGAI INPUT METODE *CONVOLUTIONAL AUTOENCODER***

Oleh:

VASSILISSA AMORYSDEO
NIM. 312110016

dari:

PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNOLOGI DAN DESAIN
UNIVERSITAS MA CHUNG

Telah dinyatakan lulus dalam melaksanakan Tugas Akhir sebagai syarat kelulusan
dan berhak mendapatkan gelar Sarjana Komputer.

Dosen pembimbing 1,

Dr. Kestrelia Rega Prilianti., M.Si.

NIP. 20120035

Dosen pembimbing 2,

Hendry Setiawan, ST., M.Kom.

NIP. 20100006

Dekan Fakultas Teknologi dan Desain,



Prof. Dr.Eng. Romy Budhi, ST., MT., M.Pd.

NIP. 20070035

PERNYATAAN KEASLIAN TUGAS AKHIR

Dengan ini saya menyatakan bahwa sebagian maupun keseluruhan Skripsi saya dengan judul “*Optimalisasi Deteksi Dini Penyakit Ganoderma pada Kelapa Sawit: Perbandingan Penggunaan Indeks Vegetasi Berbasis RGB sebagai Input Convolutional Autoencoder*” adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diizinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Malang, 20 Juli 2025



Vassilissa Amorysdeo

NIM. 312110016

UNIVERSITAS
MA CHUNG

OPTIMALISASI DETEKSI DINI PENYAKIT *GANODERMA* PADA KELAPA SAWIT: PERBANDINGAN PENGGUNAAN INDEKS VEGETASI BERBASIS RGB SEBAGAI INPUT METODE *CONVOLUTIONAL AUTOENCODER*

Vassilissa Amorysdeo, Kestrilia Rega Prilianti, Hendry Setiawan
Universitas Ma Chung

Abstrak

Industri kelapa sawit memiliki peran yang besar bagi perekonomian Indonesia karena merupakan salah satu penyumbang terbesar untuk ekspor nonmigas Indonesia. Namun, industri ini mengalami beberapa tantangan, salah satunya ialah penyakit yang disebabkan oleh jamur *Ganoderma boninense* yakni Busuk Pangkal Batang (BPB). Infeksi *Ganoderma* dapat menyebabkan penurunan panen hingga 97%. Permasalahan utama dalam pengendalian penyakit ini ialah sulitnya deteksi pada tahap awal. Maka dari itu, dibutuhkan bantuan teknologi seperti penginderaan jauh dan kecerdasan buatan untuk mendeteksi penyakit ini.

Penelitian ini berfokus pada penggunaan tiga arsitektur model *Convolutional Autoencoder* (CAE), serta penerapan dan perbandingan berbagai indeks vegetasi berbasis RGB (VARI, ExG, ExR, GLI, dan NGRDI) sebagai inputnya. Data yang digunakan berupa citra UAV berformat RGB dari tanaman sehat dan sakit yang berasal dari PT. Perkebunan Nusantara. Hasil dari eksperimen yang dilakukan menunjukkan keunggulan indeks vegetasi VARI dalam menonjolkan perbedaan citra sehat dan sakit, serta penggunaan metrik penilaian SSIM dan FSIM yang efektif dalam mengukur kinerja model deteksi anomali. Input VARI menghasilkan nilai JSD tertinggi pada model pertama dengan nilai 0.3323, nilai BD tertinggi pada model kedua dengan nilai 0.3873, serta nilai JSD dan BD tertinggi pada model ketiga dengan nilai 0.3371 dan 0.2272.

Kata kunci: *Convolutional Autoencoder*, *Ganoderma Boninense*, indeks vegetasi, penginderaan jauh

OPTIMIZATION OF EARLY DETECTION OF GANODERMA DISEASE IN OIL PALM: A COMPARISON OF RGB-BASED VEGETATION INDICES AS INPUTS FOR CONVOLUTIONAL AUTOENCODER METHOD

Vassilissa Amorysdeo, Kestriilia Rega Prilianti, Hendry Setiawan
Universitas Ma Chung

Abstract

The palm oil industry plays a significant role in the Indonesian economy as one of the largest contributors to Indonesia's non-oil and gas exports. However, this industry faces several challenges, one of which is Basal Stem Rot (BSR), a disease caused by the fungus *Ganoderma boninense*. *Ganoderma* infection can cause yield losses of up to 97%. The main challenge in controlling this disease is the difficulty of early detection. Therefore, technological assistance such as remote sensing and artificial intelligence is needed to detect this disease.

This research focuses on the use of three Convolutional Autoencoders (CAE) model architectures, as well as the application and comparison of various RGB-based vegetation indices (VARI, ExG, ExR, GLI, and NGRDI) as input. The data used were RGB-formatted UAV images of healthy and diseased plants from PT. Perkebunan Nusantara. The results of the experiments demonstrated the superiority of the VARI vegetation index in highlighting the differences between healthy and diseased images, as well as the effective use of SSIM and FSIM assessment metrics in measuring the performance of the anomaly detection model. The VARI input produces the highest JSD value in the first model with a value of 0.3323, the highest BD value in the second model with a value of 0.3873, and the highest JSD and BD values in the third model with a value of 0.3371 and 0.2272

Keywords: Convolutional Autoencoder, *Ganoderma boninense*, remote sensing, vegetation index

Kata Pengantar

Limpah puji dan syukur kepada Tuhan yang Maha Esa atas karunia dan tuntunan-Nya hingga laporan hasil Tugas Akhir ini dapat diselesaikan dengan baik. Laporan dengan judul “*Optimalisasi Deteksi Dini Penyakit Ganoderma pada Kelapa Sawit: Perbandingan Penggunaan Indeks Vegetasi Berbasis RGB sebagai Input Convolutional Autoencoder*” ini disusun sebagai pemenuhan syarat kelulusan dan pencapaian gelar Sarjana Komputer pada Program Studi Teknik Informatika Universitas Ma Chung Malang.

Sepanjang penelitian hingga penyusunan laporan ini tidak lepas dari dukungan dan bantuan berbagai pihak. Untuk itu penulis menyampaikan terima kasih yang tulus kepada:

1. Bapak Prof. Dr.Eng. Romy Budhi, ST., MT., M.Pd selaku dekan Fakultas Teknologi dan Desain Universitas Ma Chung,
2. Ibu Dr. Kestrilia Rega Prilianti., M.Si dan Bapak Hendry Setiawan, ST., M.Kom selaku dosen pembimbing tugas akhir,
3. Seluruh dosen serta staf Universitas Ma Chung, khususnya pada Program Studi Teknik Informatika Fakultas Teknologi dan Desain,
4. Keluarga dan orang-orang terkasih penulis,
5. Rekan-rekan perkuliahan, terlebih yang tergabung dalam Kelompok Riset *Precision Agriculture* (KRPA), serta
6. Pihak-pihak lain yang tidak bisa penulis sebutkan satu persatu.

Hasil dari tugas akhir ini masih memiliki banyak kekurangan, karenanya penulis sungguh terbuka terhadap kritik dan saran yang dapat memperbaiki kekurangan tersebut. Penulis berharap dengan adanya laporan tugas akhir ini dapat menjadi manfaat, khususnya pada bidang-bidang yang relevan dengan pertanian cerdas.

Malang, 20 Juli 2025



Vassilissa Amorysdeo

312110016

Daftar Isi

LEMBAR PENGESAHAN TUGAS AKHIR	i
PERNYATAAN KEASLIAN TUGAS AKHIR	ii
Abstrak	iii
<i>Abstract</i>	iv
Kata Pengantar	v
Daftar Isi	vi
Daftar Gambar	ix
Daftar Tabel	xiii
BAB I	1
Pendahuluan	1
1.1 Latar Belakang	1
1.2 Identifikasi Masalah	3
1.3 Batasan Masalah	3
1.4 Rumusan Masalah	3
1.5 Tujuan Penelitian	3
1.6 Manfaat Penelitian	4
1.7 Luaran Penelitian	4
1.8 Sistematika Penulisan	4
BAB II	6
Tinjauan Pustaka	6
2.1 Industri Kelapa Sawit	6
2.2 Penyakit Busuk Pangkal Batang (<i>Ganoderma boninense</i>)	7
2.3 Deteksi <i>Ganoderma boninense</i>	10
2.4 Indeks Vegetasi Berbasis RGB	12
2.5 Inferensi Pencitraan Jauh dengan AI	14

2.6	<i>Convolutional Autoencoder (CAE)</i>	15
2.7	<i>Quantum Geographic Information System (QGIS)</i>	19
2.8	Roboflow	20
2.9	Google Colaboratory	21
2.10	Python	21
2.11	NumPy	21
2.12	PyTorch	21
2.13	Matplotlib	22
2.14	Penelitian Terdahulu	22
BAB III		24
Analisis dan Perancangan Sistem		24
3.1	Alur Penelitian	24
3.2	Analisis Kebutuhan	25
3.2.1	Kebutuhan Pengguna	25
3.2.2	Kebutuhan Peneliti	26
3.3	Studi Literatur	26
3.4	Persiapan Dataset	27
3.5	Perancangan Model	29
3.5.1	Arsitektur model 1	29
3.5.2	Arsitektur model 2	30
3.5.3	Arsitektur model 3	31
3.6	Eksperimen Indeks Vegetasi	32
3.7	Analisis Perbandingan	33
3.8	Penentuan	34
3.9	Kesimpulan dan Rekomendasi	35
BAB IV		36

Hasil dan Pembahasan	36
4.1 Dataset	36
4.2 Preprocessing Citra Input	42
4.2.1 Dataset VARI	42
4.2.2 Dataset ExG	43
4.2.3 Dataset ExR	43
4.2.4 Dataset GLI	44
4.2.5 Dataset NGRDI	44
4.3 Arsitektur Model Autoencoder	45
4.3.1 Model 1	45
4.3.2 Model 2	46
4.3.3 Model 3	47
4.4 Hasil Pelatihan Model Autoencoder	49
4.4.1 Model 1	50
4.4.2 Model 2	56
4.4.3 Model 3	62
4.5 Perbandingan Kinerja Model berdasarkan Input	67
4.5.1 Model 1	68
4.5.2 Model 2	80
4.5.3 Model 3	92
4.5.4 Perbandingan Kinerja Metrik	105
4.6 Pembahasan	107
BAB V Simpulan dan Saran	109
5.1 Simpulan	109
5.1 Saran	110
Daftar Pustaka	111

Daftar Gambar

Gambar 2. 1 <i>Ganoderma</i> pada kelapa sawit stadium 1 (SawitNotif, 2018)	8
Gambar 2. 2 <i>Ganoderma</i> pada kelapa sawit stadium 2 (SawitNotif, 2018)	8
Gambar 2. 3 <i>Ganoderma</i> pada kelapa sawit stadium 3 (SawitNotif, 2018)	9
Gambar 2. 4 <i>Ganoderma</i> pada kelapa sawit stadium 4 (SawitNotif, 2018)	9
Gambar 2. 5 Tanaman sawit sehat (Adinata, 2025)	10
Gambar 2. 6 Tanaman sawit terinfeksi <i>Ganoderma</i>	10
Gambar 2. 7 Arsitektur CNN (Wilianto, 2021)	14
Gambar 2. 8 Arsitektur <i>Convolutional Autoencoder</i> (Meyer, 2017)	16
Gambar 3. 1 Bagan Alur Penelitian	24
Gambar 3. 2 Citra UAV kebun kelapa sawit	28
Gambar 3. 3 Arsitektur CAE yang digunakan	30
Gambar 3. 4 Citra RGB	33
Gambar 3. 5 Citra representasi indeks vegetasi	33
Gambar 4. 1 Hasil pemotongan gambar dari QGIS	36
Gambar 4. 2 Hasil pemotongan gambar dari QGIS dengan tanda posisi pohon sakit	36
Gambar 4. 3 Contoh citra sawit sehat (RGB)	37
Gambar 4. 4 Contoh citra sawit sakit (RGB)	37
Gambar 4. 5 Citra sehat untuk histogram perbandingan	38
Gambar 4. 6 Citra sakit untuk histogram perbandingan	38
Gambar 4. 7 Histogram perbandingan intensitas warna merah	38
Gambar 4. 8 Histogram perbandingan intensitas warna hijau	39
Gambar 4. 9 Histogram perbandingan intensitas warna biru	39
Gambar 4. 10 Histogram perbandingan intensitas piksel VARI	40
Gambar 4. 11 Histogram perbandingan intensitas piksel ExG	40
Gambar 4. 12 Histogram perbandingan intensitas piksel ExR	41
Gambar 4. 13 Histogram perbandingan intensitas piksel GLI	41
Gambar 4. 14 Histogram perbandingan intensitas piksel NGRDI	42
Gambar 4. 15 Contoh citra sawit sehat (VARI)	42


Gambar 4. 16 Contoh citra sawit sakit (VARI)	42
Gambar 4. 17 Contoh citra sawit sehat (ExG)	43
Gambar 4. 18 Contoh citra sawit sakit (ExG)	43
Gambar 4. 19 Contoh citra sawit sehat (ExR)	43
Gambar 4. 20 Contoh citra sawit sakit (ExR)	43
Gambar 4. 21 Contoh citra sawit sehat (GLI)	44
Gambar 4. 22 Contoh citra sawit sakit (GLI)	44
Gambar 4. 23 Contoh citra sawit sehat (NGRDI)	44
Gambar 4. 24 Contoh citra sawit sakit (NGRDI)	45
Gambar 4. 25 Grafik <i>loss</i> model 1 input RGB	50
Gambar 4. 26 Grafik <i>loss</i> model 1 input VARI	51
Gambar 4. 27 Grafik <i>loss</i> model 1 input ExG	51
Gambar 4. 28 Grafik <i>loss</i> model 1 input ExR	52
Gambar 4. 29 Grafik <i>loss</i> model 1 input GLI	52
Gambar 4. 30 Grafik <i>loss</i> model 1 input NGRDI	53
Gambar 4. 31 Hasil rekonstruksi model 1 – RGB	53
Gambar 4. 32 Hasil rekonstruksi model 1 – VARI	54
Gambar 4. 33 Hasil rekonstruksi model 1 – ExG	54
Gambar 4. 34 Hasil rekonstruksi model 1 – ExR	55
Gambar 4. 35 Hasil rekonstruksi model 1 – GLI	55
Gambar 4. 36 Hasil rekonstruksi model 1 – NGRDI	56
Gambar 4. 37 Grafik <i>loss</i> model 2 input RGB	56
Gambar 4. 38 Grafik <i>loss</i> model 2 input VARI	57
Gambar 4. 39 Grafik <i>loss</i> model 2 input ExG	57
Gambar 4. 40 Grafik <i>loss</i> model 2 input ExR	58
Gambar 4. 41 Grafik <i>loss</i> model 2 input GLI	58
Gambar 4. 42 Grafik <i>loss</i> model 2 input NGRDI	59
Gambar 4. 43 Hasil rekonstruksi model 2 – RGB	59
Gambar 4. 44 Hasil rekonstruksi model 2 – VARI	60

Gambar 4. 45 Hasil rekonstruksi model 2 – ExG	60
Gambar 4. 46 Hasil rekonstruksi model 2 – ExR	61
Gambar 4. 47 Hasil rekonstruksi model 2 – GLI	61
Gambar 4. 48 Hasil rekonstruksi model 2 – NGRDI	62
Gambar 4. 49 Grafik <i>loss</i> model 3 input RGB	62
Gambar 4. 50 Grafik <i>loss</i> model 3 input VARI	63
Gambar 4. 51 Grafik <i>loss</i> model 3 input ExG	63
Gambar 4. 52 Grafik <i>loss</i> model 3 input ExR	63
Gambar 4. 53 Grafik <i>loss</i> model 3 input GLI	64
Gambar 4. 54 Grafik <i>loss</i> model 3 input NGRDI	64
Gambar 4. 55 Hasil rekonstruksi model 3 – RGB	65
Gambar 4. 56 Hasil rekonstruksi model 3 – VARI	65
Gambar 4. 57 Hasil rekonstruksi model 3 – ExG	66
Gambar 4. 58 Hasil rekonstruksi model 3 – ExR	66
Gambar 4. 59 Hasil rekonstruksi model 3 – GLI	67
Gambar 4. 60 Hasil rekonstruksi model 3 – NGRDI	67
Gambar 4. 61 Grafik hasil pengujian model 1 input RGB	69
Gambar 4. 62 Diagram frekuensi kategori nilai JSD model 1 input RGB	70
Gambar 4. 63 Grafik hasil pengujian model 1 input VARI	71
Gambar 4. 64 Diagram frekuensi kategori nilai JSD model 1 input VARI	72
Gambar 4. 65 Grafik hasil pengujian model 1 input ExG	73
Gambar 4. 66 Diagram frekuensi kategori nilai JSD model 1 input ExG	74
Gambar 4. 67 Grafik hasil pengujian model 1 input ExR	75
Gambar 4. 68 Diagram frekuensi kategori nilai JSD model 1 input ExR	76
Gambar 4. 69 Grafik hasil pengujian model 1 input GLI	77
Gambar 4. 70 Diagram frekuensi kategori nilai JSD model 1 input GLI	78
Gambar 4. 71 Grafik hasil pengujian model 1 input NGRDI	79
Gambar 4. 72 Diagram frekuensi kategori nilai JSD model 1 input NGRDI	80
Gambar 4. 73 Grafik hasil pengujian model 2 input RGB	81

Gambar 4. 74 Diagram frekuensi kategori nilai JSD model 2 input RGB	82
Gambar 4. 75 Grafik hasil pengujian model 2 input VARI	83
Gambar 4. 76 Diagram frekuensi kategori nilai JSD model 2 input VARI	84
Gambar 4. 77 Grafik hasil pengujian model 2 input ExG	85
Gambar 4. 78 Diagram frekuensi kategori nilai JSD model 2 input ExG	86
Gambar 4. 79 Grafik hasil pengujian model 2 input ExR	87
Gambar 4. 80 Diagram frekuensi kategori nilai JSD model 2 input ExR	88
Gambar 4. 81 Grafik hasil pengujian model 2 input GLI	89
Gambar 4. 82 Diagram frekuensi kategori nilai JSD model 2 input GLI	90
Gambar 4. 83 Grafik hasil pengujian model 2 input NGRDI	91
Gambar 4. 84 Diagram frekuensi kategori nilai JSD model 2 input NGRDI	92
Gambar 4. 85 Grafik hasil pengujian model 3 input RGB	94
Gambar 4. 86 Diagram frekuensi kategori nilai JSD model 3 input RGB	95
Gambar 4. 87 Grafik hasil pengujian model 3 input VARI	96
Gambar 4. 88 Diagram frekuensi kategori nilai JSD model 3 input VARI	97
Gambar 4. 89 Grafik hasil pengujian model 3 input ExG	98
Gambar 4. 90 Diagram frekuensi kategori nilai JSD model 3 input ExG	99
Gambar 4. 91 Grafik hasil pengujian model 3 input ExR	100
Gambar 4. 92 Diagram frekuensi kategori nilai JSD model 3 input ExR	101
Gambar 4. 93 Grafik hasil pengujian model 3 input GLI	102
Gambar 4. 94 Diagram frekuensi kategori nilai JSD model 3 input GLI	103
Gambar 4. 95 Grafik hasil pengujian model 3 input NGRDI	104
Gambar 4. 96 Diagram frekuensi kategori nilai JSD model 3 input NGRDI	105

Daftar Tabel

Tabel 4. 1 Arsitektur <i>encoder</i> model 1	45
Tabel 4. 2 Arsitektur <i>decoder</i> model 1	46
Tabel 4. 3 Arsitektur <i>encoder</i> model 2	47
Tabel 4. 4 Arsitektur <i>decoder</i> model 2	47
Tabel 4. 5 Arsitektur <i>encoder</i> model 3	48
Tabel 4. 6 Arsitektur <i>decoder</i> model 3	49
Tabel 4. 7 Rata-rata JSD dan BD per indeks vegetasi model 1	80
Tabel 4. 8 Rata-rata JSD dan BD per indeks vegetasi model 2	92
Tabel 4. 9 Rata-rata JSD dan BD per indeks vegetasi model 3	105
Tabel 4. 10 Perbandingan Rata-rata JSD dan BD tiap metrik	106



UNIVERSITAS
MA CHUNG

BAB I

Pendahuluan

1.1 Latar Belakang

Sebagai salah satu negara penghasil kelapa sawit terbesar, Indonesia memiliki peran strategis dalam pemenuhan kebutuhan minyak sawit dunia. Mengikuti hal tersebut pula, industri kelapa sawit memiliki peran besar bagi perekonomian Indonesia. Data Badan Pusat Statistik menunjukkan bahwa pertumbuhan ekonomi Indonesia pada Triwulan III-2024 tercatat sejumlah 4,95%, sementara produk domestik bruto pada sektor pertanian dan perkebunan tumbuh secara positif di 1,69%. Komoditas kelapa sawit menjadi salah satu penggerak pada kedua sektor tersebut. Industri kelapa sawit juga merupakan salah satu penyumbang terbesar untuk ekspor nonmigas Indonesia. Hal ini dibuktikan dengan data Kementerian Perdagangan hingga September 2024, ekspor lemak dan minyak nabati mencapai USD 14,43 milyar, yang didalamnya termasuk pula minyak dari kelapa sawit (Kementerian Keuangan Republik Indonesia, 2024).

Industri kelapa sawit di Indonesia bukan tanpa tantangan. Salah satu permasalahan serius diakibatkan oleh hama dan penyakit, antara lain oleh jamur *Ganoderma boninense*. Jamur ini dapat menyebabkan penyakit busuk pangkal batang (BPB). Infeksi ini menyebabkan terhambatnya pertumbuhan pohon kelapa sawit, perubahan warna daun menjadi hijau pucat, serta busuk pada batang tanaman. Pada tanaman yang muda, gejala awalnya berupa menguningnya daun terbawah diikuti dengan kematian sel atau jaringan yang menyebar ke seluruh daun. Pada tanaman dewasa, semua pelepah menjadi pucat. Seluruh daun dan pelepah akan mengering sebelum akhirnya tanaman akan mati (Mahmud, Romantis, & Zam, 2020). Infeksi *Ganoderma* yang tidak terdeteksi sejak dini dapat menyebabkan penurunan hasil panen hingga 80% bahkan 97% dalam kondisi infeksi parah (Smart agribusiness and food, 2024).

Permasalahan utama dalam pengendalian penyakit busuk pangkal batang ini ialah sulitnya mendeteksi infeksi pada tahap awal. Gejala visual yang telah disebutkan sebelumnya umumnya baru akan tampak setelah infeksi jamur *Ganoderma* sudah cukup parah. Hal ini menyebabkan pengendalian sering terhambat, penyebaran penyakit semakin luas, serta berpotensi menurunkan

produktivitas kebun kelapa sawit secara signifikan (Smart agribusiness and food, 2024). Deteksi dini juga cukup sulit dilakukan mengingat adanya keterbatasan metode deteksi tradisional yang masih mengandalkan pengamatan visual serta inspeksi lapangan (Rahmana, Hayata, & Hartawan, 2024).

Dalam beberapa tahun terakhir, teknologi penginderaan jauh banyak diterapkan dalam memantau kesehatan tanaman, termasuk juga dalam deteksi penyakit *Ganoderma*. Indeks vegetasi seperti *Normalized Difference Vegetation Index* (NDVI), *Green Normalized Difference Vegetation Index* (GNDVI), dan *Soil Adjusted Vegetation Index* (SAVI) telah digunakan untuk mendeteksi perubahan spektral pada tanaman yang terkena infeksi. Tanaman yang terinfeksi memiliki nilai reflektansi lebih rendah dibandingkan tanaman sehat, dengan perbedaan yang mencolok pada pita merah, hijau, dan inframerah dekat (NIR) (Wahyuni, Sabrina, Mukhlis, & Santoso, 2022).

Seiring dengan perkembangan teknologi kecerdasan buatan, metode berbasis *machine learning* seperti *Support Vector Machine* (SVM) dan *Convolutional Neural Network* (CNN) telah diterapkan untuk deteksi penyakit pada tanaman. Algoritma SVM berhasil mencapai akurasi sebesar 93,51% dalam mengklasifikasikan tanaman yang terinfeksi *Ganoderma*, sedangkan CNN berbasis ResNet-34 menunjukkan kinerja yang baik dengan F1-score sebesar 84,61% untuk pelatihan dan 73,83% untuk pengujian (Wicaksono, Prilianti, Setiawan, & Mimboro, 2022).

Selain metode *machine learning* yang telah disebutkan, ada pula metode lainnya untuk mendeteksi gangguan pada tanaman, yakni *autoencoder*. Salah satu penelitian yang memanfaatkan *autoencoder* dalam bidang pertanian ialah oleh (Adkisson, Kimmel, Gupta, & Abdelsalam, 2021) yang mengembangkan metode deteksi anomali berbasis *autoencoder* dalam pertanian cerdas (*smart farming*). Penelitian ini menggunakan data yang telah dikumpulkan dengan berbagai sensor kemudian mendeteksi anomali yang mungkin mengindikasikan tanaman sakit. Hasil penelitian ini menunjukkan bahwa metode ini mencapai akurasi sebesar 98,98% dalam mendeteksi anomali.

Berangkat dari pendekatan serupa, penelitian ini berfokus pada penggunaan *autoencoder*, khususnya *Convolutional Autoencoder* (CAE), untuk mendeteksi

indikasi penyakit *Ganoderma* pada tanaman kelapa sawit. Input awal yang digunakan berupa citra RGB, yang kemudian akan dikembangkan lebih lanjut dengan menerapkan indeks vegetasi berbasis RGB. Indeks vegetasi merupakan teknik pengolahan citra yang memanfaatkan kombinasi saluran merah (*Red*), hijau (*Green*), dan biru (*Blue*) untuk menonjolkan karakteristik vegetasi dalam gambar. Beberapa indeks vegetasi yang akan digunakan ialah *Visible Atmospherically Resistant Index* (VARI), *Excess Green Index* (ExG), *Excess Red Index* (ExR), *Green Leaf Index* (GLI), dan *Normalized Green-Red Difference Index* (NGRDI). Dengan pendekatan ini, diharapkan model dapat lebih fokus pada informasi relevan terkait kesehatan tanaman, sehingga deteksi dini terhadap infeksi *Ganoderma* dapat dilakukan dengan lebih akurat.

1.2 Identifikasi Masalah

Permasalahan yang dihadapi ialah terbatasnya deteksi dini penyakit *Ganoderma* pada tanaman kelapa sawit secara visual, khususnya pada tahap awal, karena ciri visual baru akan muncul ketika infeksi sudah parah. Hal ini dapat menyebabkan tanaman mati dan merugikan para petani, karena untuk menanam pohon yang baru membutuhkan waktu yang cukup panjang.

1.3 Batasan Masalah

1. Data yang digunakan berasal dari PT. Perkebunan Nusantara (PTPN)
2. Data diolah menjadi indeks vegetasi berbasis RGB yaitu VARI, ExG, ExR, GLI, NGRDI
3. Data yang digunakan merupakan citra UAV berbasis RGB
4. Deteksi menggunakan model *Convolutional Autoencoder*

1.4 Rumusan Masalah

1. Bagaimana efektivitas deteksi dini *Ganoderma boninense* dapat ditingkatkan menggunakan citra berbasis indeks vegetasi?
2. Indeks vegetasi mana yang paling sesuai digunakan untuk deteksi dini *Ganoderma boninense*?

1.5 Tujuan Penelitian

1. Mengoptimalkan deteksi dini penyakit *Ganoderma* pada tanaman kelapa sawit dengan memilih input terbaik antara indeks vegetasi VARI, ExG, ExR, GLI dan NGRDI untuk model *Convolutional Autoencoder*

2. Menentukan indeks vegetasi berbasis RGB paling optimal

1.6 Manfaat Penelitian

1. Bagi PT. Perkebunan Nusantara: Menghindari kerugian lebih besar dengan mendeteksi terlebih dahulu tanaman yang terkena penyakit.
2. Bagi Peneliti: Menambah wawasan dalam bidang deteksi penyakit pada tanaman, serta memberikan kontribusi dalam penelitian terkait.
3. Bagi industri pertanian: Semakin berkembangnya teknologi *smart farming*.

1.7 Luaran Penelitian

1. Rekomendasi indeks vegetasi berbasis RGB paling optimal.
2. Analisis perbandingan efektivitas berbagai indeks vegetasi.
3. Publikasi atau artikel ilmiah terkait pengolahan citra dan deteksi penyakit tanaman.

1.8 Sistematika Penulisan

Penulisan dari laporan hasil Tugas Akhir ini disusun berdasarkan sistematika sebagai berikut:

1. Bab I: Pendahuluan

Bab I utamanya berisi latar belakang dari dilaksanakannya penelitian ini. Pada bab ini pula dijelaskan permasalahan yang akan diteliti, tujuan dan manfaat penelitian ini, hingga hasil yang diharapkan setelah penelitian selesai.

2. Bab II: Tinjauan Pustaka

Bab II berisi dasar-dasar keilmuan yang digunakan pada penelitian ini. Pada penelitian ini terlebih akan membahas penyakit busuk pangkal batang akibat jamur *Ganoderma boninense* pada tanaman kelapa sawit, dampak buruknya bagi industri, tingkatan infeksi, hingga cara mendeteksinya. Kemudian diikuti dengan pembahasan teknologi yang digunakan seperti penginderaan jauh, *Artificial Intelligent*, hingga alat-alat yang mendukung penelitian ini.

3. Bab III: Analisis dan Perancangan Sistem

Bab III berisi detail alur pelaksanaan penelitian. Pada bab ini dipaparkan bagaimana penelitian akan berjalan, dimulai dari analisis kebutuhan, persiapan hingga evaluasi model sistem deteksi, dan ditutup dengan pemberian rekomendasi.

4. Bab IV: Hasil dan Pembahasan

Pada bab ini diceritakan secara keseluruhan bagaimana hasil eksperimen-eksperimen yang telah dilakukan. Akan dipaparkan data-data yang diperoleh, berikut dengan interpretasi dan pembahasan makna dari data-data tersebut.

5. Bab V: Simpulan dan Saran

Pada bab V sebagai penutup berisi jawaban dari rumusan pertanyaan pada bab I, serta pemberian saran-saran yang berguna untuk penelitian lanjutan kedepannya.



UNIVERSITAS
MA CHUNG

BAB II

Tinjauan Pustaka

2.1 Industri Kelapa Sawit

Kelapa sawit (*Elaeis guineensis*) adalah jenis tanaman yang berasal dari Afrika, kemudian dibawa oleh orang Belanda ke Indonesia dan ditanam di Kebun Raya Bogor pada tahun 1848. Bermula dari empat biji kelapa sawit, tanaman ini dapat tumbuh subur pada beberapa daerah hingga dibudidayakan secara komersial dan meluas di Pulau Sumatera sejak tahun 1910. Sekitar tahun 1980, mulai diperkenalkan kebun sawit pola Perkebunan Inti Rakyat-Transmigrasi (PIR-Trans). Sejak saat itu, pengembangan kelapa sawit menjasi sangat pesat serta luasnya bertambah setiap tahunnya.

Industri kelapa sawit mempekerjakan kurang lebih 2.800.000 orang langsung di kebun, dan 1.600.000 diantaranya merupakan petani atau pekebun kecil. Selain itu, sekitar 3.600.000 orang merupakan keluarga karyawan yang bekerja pada perusahaan perkebunan baik swasta maupun BUMN. Hal ini menunjukkan kebun dan industri kelapa sawit menjadi tempat menggantungkan hidup dan mencari lahan pekerjaan. Industri ini menghasilkan komoditas yang dimanfaatkan untuk bahan makan pokok manusia, serta sebagai bahan baku energi nabati, sehingga cenderung kebal krisis (Supriyono, 2023).

Bagi negara, industri sawit menjadi salah satu andalan pemasukan negara, baik melalui pajak maupun pendapatan ekspor. Pada tahun 2022, devisa dari ekspor produk minyak kelapa sawit beserta turunannya mencapai USD 15 juta. Sampai dengan September 2024, kinerja ekspor lemak dan minyak nabati, termasuk didalamnya minyak kelapa sawit mencapai USD 14,43 milyar. Hal ini menunjukkan kontribusi signifikan industri kelapa sawit bagi perekonomian Indonesia (Kementerian Keuangan Republik Indonesia, 2024).

Disamping berbagai potensi industri kelapa sawit untuk masyarakat dan perekonomian Indonesia, industri ini juga menghadapi beberapa tantangan. Diantaranya ialah stagnasi produksi karena lambatnya proses peremajaan tanaman, peningkatan konsumsi domestik, serta tekanan dari regulasi internasional yang membatasi ekspor produk sawit ke Eropa (Majalah Hortus, 2024). Selain itu, terdapat perkebunan rakyat yang berada di kawasan hutan dengan status belum jelas

sehingga menghambat legalitas dan akses terhadap program pendanaan peremajaan. Tantangan lainnya terdapat pada kendala lingkungan seperti deforestasi, emisi karbon dari lahan gambut, serta kebakaran hutan (Benedict & Heilmayr, 2024). Di sisi lain, tanaman kelapa sawit juga rentan terhadap ancaman penyakit tanaman, seperti penyakit akar, penyakit busuk pangkal batang, penyakit busuk kuncup, penyakit garis kuning, anthracnose, dan penyakit tajuk (Corteva, 2020). Kompleksitas tantangan ini menunjukkan pentingnya keselarasan antara inovasi teknologi, kebijakan yang adaptif, dan budidaya yang berkelanjutan demi keberlangsungan industri sawit ke depan.

2.2 Penyakit Busuk Pangkal Batang (*Ganoderma boninense*)

Salah satu penyakit yang dapat menyerang tanaman kelapa sawit ialah Busuk Pangkal Batang (BPB) akibat jamur *Ganoderma boninense*. Serangan *Ganoderma* yang berat dapat menurunkan performa produktivitas secara linier. Penyakit ini dapat menyerang tanaman muda maupun tua dan dapat menyebabkan kematian tanaman hingga 80% (Nurliana, Ginting, Guntoro, & Fenni, 2022). Tercatat kerugian akibat *Ganoderma* pada Asia Tenggara mencapai USD 500 milyar setahun, serta pada Indonesia dan Malaysia sekitar Rp225 juta hingga Rp1,5 milyar setahun.

BPB merupakan salah satu ancaman paling merugikan dalam budidaya kelapa sawit karena menyebabkan pembusukan pada akar dan batang bagian bawah. Penyakit ini disebabkan oleh jamur *Ganoderma*, yakni jenis jamur busuk putih yang dapat merusak struktur dinding sel tanaman, terutama lignin. Infeksi jamur ini mengganggu proses transportasi nutrisi dari akar ke bagian atas tanaman, sehingga memicu gejala seperti daun layu dan menguning, terganggunya perkembangan pelepah daun muda, serta munculnya bercak-bercak pada kanopi. Pada tahap lanjut, basidiokarp atau tubuh buah jamur sering kali muncul di bagian batang bawah tanaman yang terinfeksi. Infeksi *Ganoderma* diketahui dapat menurunkan produksi minyak sawit secara signifikan. Meskipun awalnya diduga hanya menyerang tanaman tua berumur di atas 25 tahun, kasus infeksi juga telah ditemukan pada tanaman muda berumur 10 hingga 15 tahun, bahkan pada bibit berusia kurang dari 5 tahun. Penyebaran yang luas dan dampak yang ditimbulkan menjadikan penyakit ini sebagai salah satu hambatan utama dalam peningkatan

produktivitas perkebunan kelapa sawit di Indonesia (Senewe, Pesireron, & Sahetapy, 2023).

Ciri tanaman sawit yang terserang *Ganoderma* terbagi menjadi empat stadium sebagai berikut:


1. Stadium 1



Gambar 2. 1 *Ganoderma* pada kelapa sawit stadium 1 (SawitNotif, 2018)

Ciri yang tampak pada stadium pertama ini ialah warna daun menjadi hijau kekuningan dan kusam, layu seperti kekurangan air, pertumbuhan daun bagian pucuk terhambat sehingga permukaan tajuk daun menjadi rata, dan pertumbuhan bunga betina dan buah terhambat.

2. Stadium 2




Gambar 2. 2 *Ganoderma* pada kelapa sawit stadium 2 (SawitNotif, 2018)

Pada stadium kedua, daun berwarna hijau pucat kekuningan dan kusam, pelepah bawah dan anak daun mengering, muncul dua daun tombak yang tidak

membuka, tumbuh hifa dan miselia *Ganoderma* pada pangkal batang dan akar serta menyebar pada pertemuan ketiak pelepah sawit, produksi tandan buah segar menurun 50% dan proses kematangannya terganggu.


3. Stadium 3



Gambar 2. 3 *Ganoderma* pada kelapa sawit stadium 3 (SawitNotif, 2018)

Pada stadium ketiga pelepah dan anak daun mengering dan patah pada tingkat pelepah kedua sampai dengan keenam, muncul tiga daun tombak tidak membuka pada bagian pucuk, tumbuh basidiokarp *Ganoderma* pada pangkal batang, pembuluh xilem dan floem 75% tidak berfungsi, pertumbuhan vegetatif terhenti yang dapat menyebabkan kehilangan produksi hingga 80%

4. Stadium 4



Gambar 2. 4 *Ganoderma* pada kelapa sawit stadium 4 (SawitNotif, 2018)


Pada stadium terakhir basidiokarp *Ganoderma* telah tumbuh mengelilingi batang pohon, seluruh daun mengering, berpatahan, serta menggantung di pohon,

pembuluh xilem dan floem mati. Dalam jangka waktu 6 – 12 bulan tanaman akan mati total dan tumbang, dan dapat menginfeksi pohon sehat lainnya dalam radius 200 meter (SawitNotif, 2018).

Untuk mendukung pemahaman terkait gejala visual daun kelapa sawit, berikut ditampilkan contoh citra kelapa sawit hasil penginderaan jauh baik yang sakit maupun sehat. Citra sakit berasal dari citra satu buah pohon yang diambil secara berkala dengan interval satu bulan selama lima bulan sebelum tumbang.



Gambar 2. 5 Tanaman sawit sehat (Adinata, 2025)



Gambar 2. 6 Tanaman sawit terinfeksi *Ganoderma*

Gambar 2.6a menunjukkan visual pohon lima bulan sebelum tumbang. Warna daun tampak mulai berubah kekuningan dan beberapa daun mulai mengering. Pada bulan setelahnya di Gambar 2.6b, semakin banyak daun yang mengering dan rontok. Hal ini terjadi hingga pohon tampak seperti Gambar 2.6e, yang mana berakhir tumbang di bulan berikutnya. Perubahan warna dan visual ini menunjukkan penurunan kesehatan pohon sawit secara progresif sejalan dengan perkembangan infeksi *Ganoderma*.

2.3 Deteksi *Ganoderma boninense*

Secara konvensional, tanaman kelapa sawit yang terserang *Ganoderma* dapat diidentifikasi melalui kemunculan gejala seperti akumulasi daun tombak lebih dari tiga, adanya busuk pada pangkal batang, serta memucatnya warna daun. Pengamatan seperti ini memang mudah dilakukan tanpa peralatan khusus, namun ketika gejala-gejala tersebut tampak, biasanya tanaman sudah terserang sangat

parah sehingga sulit untuk dipertahankan. Selain itu sering juga ditemukan tanaman tanpa gejala yang kemudian tumbang (Ginting & Wiratmoko, 2021).

Metode deteksi lain yang telah dilakukan ialah dengan teknik Polymerase Chain Reaction (PCR), yaitu dengan mengumpulkan sampel akar tanaman yang terinfeksi, kemudian isolat *Ganoderma* dimurnikan dengan *potato dextrose agar* (PDA). Setelah itu, keberadaan patogen dideteksi dengan memperbanyak fragmen DNA spesifik dari *Ganoderma*. Teknik ini dapat menghasilkan deteksi dini penyakit secara efektif (Karunarathna, Patabendige, Lu, Asad, & Hapuarachchi, 2024). Namun penggunaan tes ini sulit dilakukan di lapangan karena membutuhkan berbagai tahapan, alat dan laboratorium dengan keahlian khusus, serta biaya yang besar (Redaksi SawitKita, 2024).

Alternatif lain yang dapat digunakan untuk mendeteksi *Ganoderma* secara lebih praktis di lapangan adalah metode serologi, salah satunya menggunakan teknik *Dot Immunobinding Assay* (DIBA). Metode ini bekerja dengan mendeteksi keberadaan antigen *Ganoderma* melalui ikatan antara antigen dan antibodi spesifik, kemudian menghasilkan reaksi warna yang mudah diamati. DIBA terbukti mampu mengenali antigen dari miselium *Ganoderma* sp. pada konsentrasi hingga 138 µg/mL dan berhasil diuji baik di laboratorium, rumah kaca, maupun di lapangan. Keunggulan utama dari metode ini adalah prosesnya yang cepat, sederhana, tidak memerlukan peralatan canggih, dan dapat diterapkan langsung di lapangan, sehingga potensial sebagai metode deteksi dini yang efisien. Namun demikian, DIBA juga memiliki beberapa keterbatasan, seperti sensitivitas yang masih terbatas pada konsentrasi antigen tertentu, potensi reaksi silang dengan antigen dari organisme lain yang dapat menyebabkan hasil positif palsu, serta hasil yang bersifat semi-kuantitatif sehingga kurang akurat untuk mengetahui tingkat keparahan infeksi (Suharyanto, Eris, Prakoso, Saragih, & Darmono, 2016).

Dalam beberapa tahun terakhir penggunaan *Unmanned Aerial Vehicle* (UAV) atau drone sebagai media penginderaan jauh untuk memantau kesehatan tanaman menjadi solusi inovatif dan efektif. Drone digunakan untuk menangkap gambar yang kemudian diekstraksi untuk mengambil informasi dan membuat keputusan terkait stres fisiologis tanaman. Pada saat ini drone telah dilengkapi dengan kamera multispektral yang berperan dalam menyediakan beragam

informasi seperti jumlah tanaman, status nutrisi nitrogen, dan kesehatan tanaman (Sakti, Khurizil, Aprilia, Sudarti, & Trapsilo, 2023).

Penggunaan UAV juga secara spesifik digunakan untuk mendeteksi penyakit *Ganoderma* pada tanaman kelapa sawit seperti pada penelitian oleh (Wicaksono, Prilianti, Setiawan, & Mimboro, 2022). Citra yang diambil dengan penginderaan jauh kemudian diekstraksi untuk mendapatkan rata-rata nilai RGB dari setiap pokok pohon. Nilai rata-rata inilah yang kemudian digunakan sebagai input untuk mendeteksi terinfeksi atau tidaknya pohon tersebut. Pada umumnya, tanaman yang terinfeksi *Ganoderma* menunjukkan pola pantulan yang berbeda dibandingkan dengan tanaman sehat. Perubahan ini terlihat jelas pada spektrum warna merah (*Red*) dan dekat inframerah (NIR), di mana tanaman yang terinfeksi cenderung memiliki penurunan pantulan pada NIR dan peningkatan pantulan pada spektrum merah. Kamera RGB, yang menggunakan tiga saluran warna (Merah, Hijau, Biru), dapat mendeteksi perubahan visual seperti daun yang menguning atau pola pertumbuhan abnormal, tetapi sering kali hanya efektif pada tahap infeksi yang sudah lebih lanjut. Di sisi lain, kamera RGB-NIR, yang dilengkapi dengan saluran *Near-Infrared* (NIR), memberikan keuntungan tambahan karena dapat mendeteksi perubahan fisiologis pada tanaman, seperti penurunan kandungan klorofil, yang memungkinkan deteksi dini penyakit *Ganoderma* sebelum gejala fisik muncul (Anuar, Noor, Seman, & Hamzah, 2020).

2.4 Indeks Vegetasi Berbasis RGB

Indeks vegetasi merupakan nilai yang didapat dari gabungan informasi spektral yang dimiliki sebuah citra satelit untuk menghitung tingkat aktifitas fotosintesis dan kepadatan vegetasi pada sebuah daerah (Rahmawati & Hermawan, 2023). Sebuah indeks vegetasi terbentuk dari kombinasi beberapa nilai spektral dengan menambahkan, membagi, maupun mengalikan untuk menghasilkan sebuah nilai tunggal yang menunjukkan jumlah atau kekuatan dalam piksel. Nilai indeks vegetasi yang tinggi mengidentifikasi piksel didominasi oleh tanaman-tanaman yang sehat (Prasetya & Insan, 2021).

Indeks *Visible Atmospherically Resistant Index* (VARI) sesuai untuk citra RGB atau gambar berwarna karena bekerja dengan seluruh segmen spektrum elektromagnetik yang terlihat, yang mencakup pita merah, hijau, dan biru. VARI

secara spesifik bekerja untuk meningkatkan visibilitas vegetasi terutama pada atmosfer yang tidak ideal, serta membantu meratakan pencahayaan citra. Salah satu keunggulan VARI ialah memiliki sensitivitas yang rendah terhadap gangguan atmosfer sehingga kesalahan pemantauan dengan indeks ini berada di bawah 10%. Rumus untuk VARI ialah:

$$VARI = \frac{Green - Red}{Green + Red - Blue} \text{ (Sergieieva, 2025)} \quad (2-1)$$

Indeks *Excess Green Index* (ExG) merupakan nilai koordinat kromatik yang diperoleh dari selisih antara normalisasi kanal hijau dengan nilai maksimum masing-masing kanal merah dan biru (Soesanto, Idris, & Hastomo, 2022). ExG cenderung sensitif terhadap kandungan klorofil pada tanaman. Maka dari itu, nilai ExG yang tinggi mengindikasikan tanaman sehat sedangkan nilai rendah menandakan tanaman sedang stres atau rusak (Radočaj, Šiljeg, Marinović, & Jurišić, 2023). Nilai ExG diperoleh dari rumus berikut:

$$ExG = 2 \times Green - Red - Blue \quad (2-2)$$

Indeks *Excess Red Index* (ExR) memiliki sensitifitas tinggi terhadap kepadatan serta distribusi tanaman. Oleh karena itu, indeks ini sesuai untuk dijadikan pelengkap dalam penilaian kondisi tanaman yang dilakukan oleh ExG dengan menyediakan informasi tambahan berupa biomassa tanaman (Radočaj, Šiljeg, Marinović, & Jurišić, 2023). Nilai ExR dapat dihitung dengan persamaan berikut:

$$ExR = 1,4 \times Red - Green \text{ (Soesanto, Idris, \& Hastomo, 2022).} \quad (2-3)$$

Indeks *Green Leaf Index* (GLI) merupakan indeks yang memiliki kepekaan tinggi terhadap warna kehijauan pada daun. Indeks ini menggunakan kanal warna merah, hijau, dan biru karena ketiga kanal tersebut mampu menunjukkan sensitifitas pada kandungan klorofil. Oleh karena itu, GLI dapat menonjolkan area vegetasi yang ditandai dengan warna hijau pada citra dengan lebih optimal. Rumus yang digunakan untuk menghitung nilai GLI ialah:

$$GLI = \frac{2 \times Green - Red - Blue}{2 \times Green + Red + Blue} \text{ (Armita, et al., 2022).} \quad (2-4)$$


Indeks *Normalized Green-Red Difference Index* (NGDRI) merupakan indeks vegetasi yang diperoleh dari selisih antara kanal hijau dan merah pada sebuah citra, kemudian nilai tersebut dinormalisasi dengan membaginya dengan

jumlah kedua kanal tersebut. Teknik normalisasi ini dirancang untuk meminimalisir pengaruh variasi kondisi pencahayaan maupun eksposur yang dapat memengaruhi hasil analisis citra. Nilai dari NGRDI dapat dihitung dengan rumus berikut:

$$\text{NGRDI} = \frac{\text{Green} - \text{Red}}{\text{Green} + \text{Red}} \quad (\text{Vianna, et al., 2025}). \quad (2-5)$$

2.5 Inferensi Pencitraan Jauh dengan AI

Untuk dapat menjaga kualitas tanaman sawit, perlu dilakukan pengawasan secara menyeluruh. Hal ini dapat menguras sumber daya serta waktu yang besar jika dilakukan secara konvensional atau manual. Maka dari itu, diperlukan sebuah sistem otomatisasi proses ini, salah satunya dengan pencitraan jauh berbasis *Unmanned Aerial Vehicle* (UAV) atau drone yang dapat mengambil gambar area perkebunan dengan efisien. Gambar atau citra ini kemudian dapat dianalisis untuk berbagai keperluan seperti pemantauan produktivitas dan deteksi pohon secara individual. Bersamaan dengan hal ini, beberapa tahun terakhir deteksi pohon atau tanaman dilakukan dengan metode-metode deteksi objek berbasis *Artificial Intelligence* (AI). Dua keluarga model deteksi objek yang paling populer digunakan adalah *Region-Based Convolutional Neural Network* (R-CNN) dan *You Only Look Once* (YOLO). Menurut beberapa studi, model YOLO dikenal memiliki keunggulan dalam kecepatan proses pelatihan dan inferensi, serta memiliki kemampuan yang baik dalam membedakan warna, bentuk, dan ukuran objek. Oleh karena itu, YOLO menjadi pilihan yang tepat dalam studi deteksi pohon kelapa sawit, karena karakteristik tajuk pohon yang kompleks serta variasi warna yang berkaitan dengan tipe dan kondisi kesehatannya (Nuwara, Wong, & Juwono, 2022).



Gambar 2. 7 Arsitektur CNN (Wilianto, 2021)


Proses inferensi citra UAV dengan arsitektur CNN berbasis YOLO dimulai dengan persiapan dataset yang akan digunakan untuk pelatihan. Setelah itu, dilakukan juga pemilihan versi dan tipe model YOLO untuk menyesuaikan dengan kompleksitas dataset. Selanjutnya dilakukan konfigurasi parameter pelatihan sebelum akhirnya model dilatih dan dievaluasi. Evaluasi model menggunakan precision atau jumlah prediksi positif yang dibuat oleh model, recall atau jumlah sampel positif yang berhasil diprediksi model, serta F1-score atau rata-rata antara precision dan recall yang menggambarkan kinerja model secara general (Adinata, 2025).

2.6 *Convolutional Autoencoder (CAE)*

Autoencoder merupakan salah satu jenis arsitektur jaringan saraf yang dirancang untuk mengompresi (*encode*) data input menjadi representasi fitur penting yang lebih sederhana kemudian merekonstruksi (*decode*) kembali data asli dari hasil kompresi tersebut. *Autoencoder* termasuk dalam metode pembelajaran tanpa pengawasan (*unsupervised learning*), dan dilatih untuk menemukan variabel laten atau variabel tersembunyi dari data input. Variabel-variabel ini tidak nampak secara langsung pada data tetapi berperan penting dalam menginformasikan distribusi data. Kumpulan dari variabel laten yang ditemukan pada data disebut ruang laten atau *latent space*. Selama pelatihan, *autoencoder* mempelajari variabel-variabel laten yang paling berpengaruh untuk rekonstruksi data seakurat mungkin. *Autoencoder* pada umumnya digunakan dalam tugas kecerdasan buatan yang berkaitan dengan ekstraksi fitur, seperti kompresi data, menghilangkan noise pada gambar (*image denoising*), deteksi anomali, serta pengenalan wajah (Bergmann & Stryker, 2023).

Convolutional Autoencoder (CAE) merupakan salah satu varian dari *autoencoder* yang dirancang khusus untuk memproses data citra atau gambar. CAE memanfaatkan lapisan konvolusi untuk mengekstraksi fitur dari gambar sehingga gambar yang dihasilkan relatif lebih kecil (Team Algoritma, 2023). Arsitektur dari CAE terdiri dari tiga komponen utama yakni *encoder*, *bottleneck*, serta *decoder*. *Encoder* berfungsi dalam ekstraksi dan kompresi fitur penting dari citra input ke dalam representasi dengan dimensi lebih rendah. Representasi ini kemudian masuk ke *bottleneck* yang berperan dalam seleksi informasi paling relevan untuk

diteruskan ke tahap rekonstruksi. *Bottleneck* membatasi aliran informasi dengan hanya mengizinkan bagian paling penting dari representasi tersebut untuk melewati *decoder*. Selanjutnya, *decoder* bertugas untuk membangun kembali data input berdasarkan informasi dari *bottleneck* (Mukherjee, 2023). Diagram arsitektur dari *Convolutional Autoencoder* adalah sebagai berikut:



Gambar 2. 8 Arsitektur *Convolutional Autoencoder* (Meyer, 2017)

Salah satu penelitian yang menggunakan *autoencoder* khususnya dalam bidang deteksi anomali ialah penelitian oleh (Mujkic, Philipsen, Moeslund, Christiansen, & Ravn, 2022) yang mengembangkan metode untuk mendeteksi objek tidak dikenal pada ladang pertanian supaya kendaraan otonom dapat berjalan dengan lebih aman. Penelitian tersebut mencoba beberapa jenis *autoencoder*, yakni *Basic AE*, *Denoising AE* (DAE), *Vector-Quantized AE* (VAE), serta *Semi-supervised AE* (SSAE). Hasil penelitian tersebut menunjukkan kinerja terbaik didapatkan dengan SSAE dengan nilai PR AUC sebesar 0,9353.

Kinerja CAE dalam rekonstruksi citra dapat dihitung dengan skor *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Learned Perceptual Image Patch Similarity* (LPIPS), *Structural Similarity Index Measure* (SSIM) dan *Feature Similarity Index* (FSIM). MAE dan MSE digunakan untuk mengukur selisih numerik antara citra asli dan citra hasil rekonstruksi secara langsung. MAE menghitung rata-rata dari perbedaan absolut tiap piksel, sedangkan MSE menghitung rata-rata dari kuadrat perbedaan tersebut, sehingga lebih sensitif terhadap kesalahan besar. Nilai MAE dan MSE yang rendah menunjukkan bahwa citra hasil rekonstruksi semakin mirip dengan citra aslinya. Rumus yang digunakan untuk menghitung MAE adalah:

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - O_i| \quad (2-6)$$

Sedangkan untuk MSE ialah:

$$MSE = \frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2 \quad (2-7)$$

Keterangan:

n = jumlah total piksel

P_i = nilai piksel hasil prediksi (rekonstruksi)

O_i = nilai piksel asli (Robeson & Willmott, 2023).

Selanjutnya, LPIPS mengukur kesamaan persepsi antar citra secara lebih akurat. LPIPS memanfaatkan jaringan saraf dalam yang telah dilatih sebelumnya untuk mengekstrak fitur dari citra. Metrik ini menghitung jarak Euclidean di ruang laten dari dua citra, sehingga mampu menangkap perbedaan visual secara semantik. Karena menggunakan representasi fitur dari jaringan saraf, LPIPS mampu mengukur perbedaan visual secara lebih mendekati persepsi manusia (Ghazanfari, Garg, Krishnamurthy, Khorrami, & Araujo, 2023). Rumus yang digunakan adalah sebagai berikut:

$$d(x, x_0) = \sum_j \frac{1}{W_j H_j} \sum_{h,w} \|\phi^j(x) - \phi^j(x_0)\|_2^2 \quad (2-8)$$

di mana $\phi^j(\cdot)$ didefinisikan sebagai:

$$\phi^j(x) = w_j \odot o_{hw}^j \quad (2-9)$$

dengan $o^j(x)$ dan $o^j(x')$ merupakan aktivasi internal dari sebuah jaringan saraf konvolusional yang telah dilatih, yang telah diskalakan per kanal menggunakan vektor bobot w_j .

Sementara itu, SSIM digunakan untuk mengevaluasi kemiripan struktural antara dua citra, dengan mempertimbangkan aspek luminansi, kontras, dan struktur. SSIM dinilai lebih merepresentasikan persepsi visual manusia terhadap kualitas citra dibandingkan dengan MAE dan MSE. Nilai SSIM berada pada rentang $[-1, 1]$, di mana nilai mendekati 1 menunjukkan kesamaan struktural yang lebih

tinggi (Adinata, 2025). Oleh karena itu, ketiga metrik ini sering digunakan secara bersamaan untuk memberikan gambaran yang lebih menyeluruh terhadap kualitas hasil rekonstruksi (Dohmen, Klemens, Baltruschat, Truong, & Lenga, 2025). Nilai SSIM dapat dihitung dengan rumus berikut:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (2-10)$$

Keterangan:

x dan y = dua citra yang dibandingkan

μ_x dan μ_y = rata-rata intensitas dari x dan y

σ_x^2 dan σ_y^2 = variansi dari x dan y

σ_{xy} = kovarians antara x dan y

C_1 dan C_2 = konstanta kecil untuk stabilitas perhitungan (Pandey, 2024).

Metrik terakhir, yakni FSIM adalah metrik yang dirancang untuk menilai kualitas citra berdasarkan persepsi visual manusia. Metrik ini pertama kali dikembangkan untuk citra grayscale dan kemudian diperluas ke versi warna yang disebut FSIMc. FSIM membandingkan dua citra dengan menghitung tingkat kesamaan berdasarkan dua fitur penting, yaitu *phase congruence* (PC) dan *gradient magnitude* (GM). PC digunakan untuk mengidentifikasi fitur penting seperti tepi, tekstur, dan sudut, sementara GM mencerminkan perbedaan intensitas atau kontras pada citra. Kedua fitur ini dikombinasikan ke dalam peta kesamaan lokal, lalu dihitung secara menyeluruh untuk mendapatkan nilai kualitas akhir (Frackiewicz, Machalicha, & Palus, 2024). Rumus untuk mendapatkan FSIM ialah:

$$FSIM = \frac{\sum_{(x,y) \in \Omega} S_{PC}(x, y) \cdot S_G(x, y) \cdot PC_m(x, y)}{\sum_{(x,y) \in \Omega} PC_m(x, y)} \quad (2-11)$$

Keterangan:

Ω = area yang dibandingkan

$S_{PC}(x, y)$ = peta kesamaan berdasarkan *phase congruence* (struktur lokal seperti tepi/tekstur).

$S_G(x, y)$ = peta kesamaan berdasarkan *gradient magnitude* (perbedaan kontras/intensitas).

$PC_m(x, y)$ = nilai maksimum *phase congruence* antara citra referensi dan citra uji pada piksel (x, y) , digunakan sebagai bobot.

Kinerja model dalam menunjukkan perbedaan antara citra sawit sehat dan sakit juga dapat dinilai berdasarkan perbedaan distribusi nilai metrik-metrik diatas. Menghitung perbedaan distribusi ini dapat dilakukan dengan menghitung nilai *Jensen-Shannon Divergence* (JSD) dan *Bhattacharyya Distance* (BD). JSD merupakan ukuran statistik yang digunakan untuk menghitung perbedaan antara dua distribusi probabilitas. JSD bersifat simetris dan selalu memberikan nilai terbatas antara 0 dan 1. Secara konseptual, JSD mengukur rata-rata dari KL *Divergence* dua distribusi terhadap distribusi rata-ratanya. Hal ini memungkinkan JSD digunakan untuk membandingkan distribusi probabilitas secara lebih stabil dan *interpretable*, terutama dalam konteks machine learning, di mana distribusi sering kali tidak sepenuhnya tumpang tindih. Semakin kecil nilai JSD, maka semakin mirip kedua distribusi yang dibandingkan (Dhinakaran, 2023). Sedangkan BD merupakan cara untuk mengkuantifikasi perbedaan antara dua distribusi probabilitas dengan memberi informasi tentang seberapa besar tumpang tindih antara kedua distribusi tersebut. Dengan informasi tersebut, dapat disimpulkan seberapa mirip atau tidak miripnya kedua distribusi tersebut (Avneon, 2023).

2.7 Quantum Geographic Information System (QGIS)

Quantum GIS (QGIS) merupakan sebuah perangkat lunak Sistem Informasi Geografis (SIG) berbasis *open-source* yang menyediakan berbagai fitur untuk visualisasi, pengolahan, dan analisis data spasial. QGIS mendukung berbagai format data serta menyediakan antarmuka pengguna yang intuitif dan mudah digunakan, sehingga banyak dimanfaatkan dalam penelitian dan aplikasi praktis pada berbagai bidang (Gama Statistika, 2024). Salah satu keunggulan QGIS ialah fleksibilitasnya yang tinggi karena memungkinkan pengguna menambahkan *plugin* tambahan sesuai kebutuhan, serta dukungan komunitas yang luas yang terus mengembangkan fungsionalitasnya secara berkelanjutan (Wicaksono G. , 2023).

Dalam berbagai penelitian, QGIS telah dimanfaatkan untuk beragam keperluan seperti pemetaan fasilitas publik, analisis pertanian, serta perencanaan kota berbasis spasial. QGIS juga memungkinkan pengguna untuk memanipulasi dan memotong citra resolusi tinggi menjadi potongan-potongan kecil, sehingga mudah diolah dalam proses analisis berbasis AI. Dalam konteks penelitian ini, QGIS digunakan untuk melakukan pemrosesan awal terhadap citra *input*,

khususnya untuk membagi citra berukuran besar menjadi tile yang sesuai dengan kebutuhan model *Convolutional Autoencoder* (CAE). Proses ini penting untuk memastikan bahwa model dapat memproses data secara efisien dan optimal.

2.8 Roboflow

Roboflow adalah *platform* berbasis *cloud* yang dirancang untuk mempermudah pengelolaan dan pengolahan data citra dalam proyek *computer vision*, mulai dari tahap anotasi, augmentasi, hingga ekspor dataset untuk pelatihan model *machine learning*. Salah satu keunggulan Roboflow adalah kemudahan antarmuka untuk melakukan anotasi gambar, yang mencakup berbagai jenis label seperti *bounding boxes*, poligon, dan *mask segmentation*. Dengan fitur ini, pengguna dapat menandai objek-objek dalam gambar dengan cepat dan efisien, yang sangat berguna dalam membangun dataset yang diperlukan untuk pelatihan model.

Selain anotasi, Roboflow juga menyediakan berbagai teknik augmentasi gambar yang dapat memperkaya variasi data untuk meningkatkan performa model. Teknik augmentasi ini meliputi rotasi, *flipping*, *zooming*, serta perubahan pencahayaan dan warna, yang berfungsi untuk mencegah *overfitting* dan meningkatkan generalisasi model. Fitur augmentasi ini penting dalam penelitian yang membutuhkan data yang lebih variatif dari citra-citra yang terbatas. Setelah dataset siap, Roboflow memungkinkan pengguna untuk mengekspor dataset dalam berbagai format yang kompatibel dengan berbagai *framework machine learning* seperti TensorFlow, PyTorch, dan YOLO, sehingga mempercepat integrasi ke alur pengembangan model (Dwyer & Gallagher, 2023).

Dalam konteks penelitian ini, Roboflow digunakan untuk mempersiapkan dataset citra sawit dengan cara menandai dan menyesuaikan gambar-gambar sesuai kebutuhan, serta mengonversi dataset ke format yang sesuai untuk digunakan dalam pelatihan model *Convolutional Autoencoder* (CAE). Meskipun CAE adalah model *unsupervised* yang tidak memerlukan label untuk pelatihan, Roboflow tetap berperan penting dalam memastikan konsistensi ukuran gambar dan format dataset agar dapat diolah dengan baik dalam proses pelatihan.

2.9 Google Colaboratory

Google Colaboratory atau Google Colab merupakan sebuah produk dari Google *Research* berupa layanan *cloud computing* yang disediakan untuk mendukung pengembangan dan penelitian ilmiah. Colab memungkinkan penggunaanya untuk menulis hingga mengeksekusi kode Python apapun melalui browser. Colab sangat sesuai untuk *machine learning*, analisis data, dan pendidikan. Layanan ini juga dapat digunakan secara bersama-sama oleh para pengembang aplikasi untuk mendukung kebutuhan kolaborasi antar anggota tim (Wilyani, Arif, & Aslimar, 2024).

2.10 Python

Python merupakan sebuah bahasa pemrograman tingkat tinggi yang digemari oleh para pengembang aplikasi karena terkenal memiliki isntaks yang sederhana, mudah dipahami, serta fleksibel. Python memiliki berbagai kegunaan termasuk didalamnya untuk pengembangan perangkat lunak, analisis data, kecerdasan buatan, pengembangan web, dan lebih banyak lagi. Bahasa pemrograman ini menjadi pilihan utama bagi banyak pengembang karena kombinasi kejelasan sintaksis dan kemampuannya untuk menangani berbagai tugas pemrograman (Wilyani, Arif, & Aslimar, 2024).

2.11 NumPy

NumPy (Numerical Python) merupakan sebuah pustaka fundamental dalam ekosistem Python yang digunakan untuk komputasi numerik berbasis array. NumPy menyediakan struktur array multidimensi yang efisien serta fungsi matematis tingkat tinggi yang dibutuhkan dalam pengolahan citra dan *machine learning* (Harris, et al., 2020). Dalam penelitian ini, NumPy digunakan untuk mengelola data citra, melakukan operasi matematis, serta menjadi dasar untuk penggunaan bersama dengan pustaka lain.

2.12 PyTorch

PyTorch adalah pustaka *open-source* untuk *machine learning* dan *deep learning* yang dikembangkan oleh Facebook AI Research. PyTorch menyediakan antarmuka yang fleksibel dan dinamis untuk membangun serta melatih model jaringan saraf. Salah satu keunggulan PyTorch ialah kemampuannya dalam membangun model dengan pendekatan berbasis *dynamic computational graph* yang

memudahkan *debugging* dan eksperimen dalam pengembangan model (Paszke, et al., 2019). Pada penelitian ini, PyTorch dimanfaatkan untuk membangun serta melatih model *Convolutional Autoencoder* (CAE).

2.13 Matplotlib

Matplotlib merupakan salah satu pustaka visualisasi data yang paling luas digunakan dalam Python. Matplotlib menjadi alat penting untuk analisis dan interpretasi data secara visual dengan kemampuannya untuk membuat berbagai jenis grafik. Keunggulan Matplotlib terletak pada fleksibilitas tinggi dan kontrol penuh terhadap elemen visualisasi. Versi terbaru dari Matplotlib terus dikembangkan oleh komunitas *open-source* dan dokumentasi resminya dapat diakses dengan mudah (Hunter, Dale, Firing, & Droettboom, 2023). Dalam penelitian ini, Matplotlib digunakan untuk menampilkan hasil evaluasi model serta perbandingan visual antara citra input dengan hasil rekonstruksi.

2.14 Penelitian Terdahulu

Penelitian terkait deteksi penyakit, khususnya *Ganoderma* pada kelapa sawit telah beberapa kali dilakukan. Penelitian oleh (Adinata, 2025) menggunakan *Convolutional Autoencoder* (CAE) untuk mendeteksi pohon kelapa sawit yang terinfeksi *Ganoderma*. Hasil penelitian ini menunjukkan performa model dalam mengidentifikasi pohon sehat dan sakit masih kurang. Peneliti tersebut juga memberi saran untuk mengganti input gambar menjadi citra VARI.

Penelitian yang dilakukan oleh (Prayogo, 2023) berfokus pada penggunaan arsitektur Recurrent Neural Network (RNN) yang dikombinasikan dengan konvolusi, seperti ConvLSTM dan ConvBiLSTM, untuk membentuk kembali *heatmap* indeks vegetasi (VARI). Hasil penelitian tersebut menunjukkan bahwa model dengan arsitektur konvolusional berhasil mempelajari data dan menghasilkan *heatmap* yang lebih akurat dibandingkan dengan model RNN biasa seperti LSTM. Model ConvBiLSTM dengan optimizer Adam dan model ConvLSTM dengan optimizer Nadam berhasil mencapai nilai *Mean Squared Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE) yang rendah serta mampu merekonstruksi *heatmap* secara visual mendekati data *ground truth*. Sebaliknya, arsitektur LSTM tanpa konvolusi cenderung mengalami *overfitting* dan gagal dalam membentuk *heatmap* dengan baik.

Penelitian lainnya yang dilakukan oleh (Wicaksono, Prilianti, Setiawan, & Mimboro, 2022) berhasil mengembangkan dua model utama, yaitu model CNN untuk deteksi objek dan model Artificial Neural Network (ANN) untuk prediksi serangan *Ganoderma*. Model CNN yang digunakan untuk mendeteksi pohon kelapa sawit berhasil dioptimalkan dengan menggunakan *backbone* ResNet-34 pada ArcGIS Pro, dan menunjukkan peningkatan signifikan dibandingkan model sebelumnya. Hasil deteksi terbaik diperoleh dari model yang dilatih menggunakan citra UAV bulan November 2021, dengan kualitas sedang, menghasilkan F1-score sebesar 0.84611 (*insample*) dan 0.73837–0.69785 (*outsample*). Hal ini juga menegaskan bahwa kualitas citra sangat mempengaruhi akurasi model deteksi. Selain itu, model ANN untuk prediksi serangan *Ganoderma* dengan input nilai RGB berhasil mencapai akurasi tertinggi sebesar 96% dan loss sebesar 0.1633, menggunakan arsitektur 13 layer. Sebaliknya, penggunaan indeks vegetasi VARI sebagai input menunjukkan performa yang kurang memuaskan, karena perbedaan nilai mean dan median antara pohon sehat dan terinfeksi tidak cukup signifikan. Akurasi model dengan input median VARI hanya mencapai 82.67% dan mean VARI sebesar 74%, dengan loss yang lebih tinggi dibandingkan input RGB.


UNIVERSITAS
MA CHUNG

BAB III

Analisis dan Perancangan Sistem

3.1 Alur Penelitian

Penelitian ini dilakukan secara bertahap dan sistematis untuk mencapai tujuan utama, yaitu mengoptimalkan deteksi dini penyakit *Ganoderma* pada kelapa sawit menggunakan metode *Convolutional Autoencoder* (CAE) dengan memanfaatkan berbagai jenis indeks vegetasi berbasis RGB. Untuk mempermudah pemahaman terhadap proses yang dilakukan, disusunlah alur penelitian yang menggambarkan setiap langkah utama dalam proses analisis dan perancangan sistem.



Gambar 3. 1 Bagan Alur Penelitian

Alur ini dimulai dari analisis kebutuhan untuk mengetahui apa saja yang dibutuhkan dalam penelitian, kemudian dilanjutkan dengan studi literatur untuk memperkuat dasar teori. Literatur bersumber dari jurnal, *website*, serta beberapa penelitian terdahulu dari mahasiswa-mahasiswa Universitas Ma Chung. Setelah itu dilakukan persiapan dataset yang digunakan dalam pelatihan dan pengujian model.

Selanjutnya, dilakukan perancangan model CAE serta eksperimen menggunakan berbagai indeks vegetasi seperti VARI, ExG, ExR, GLI, dan NGRDI.

Tahapan berikutnya adalah analisis perbandingan performa model berdasarkan masing-masing input indeks vegetasi, yang diukur dengan metrik evaluasi untuk CAE seperti MAE, MSE, dan SSIM. Setelah hasil dievaluasi, dilakukan penentuan terhadap model dan jenis indeks vegetasi terbaik. Akhirnya, penelitian ditutup dengan penarikan kesimpulan serta pemberian rekomendasi untuk penelitian selanjutnya.

3.2 Analisis Kebutuhan

Pada tahap ini dilakukan identifikasi terhadap kebutuhan sistem yang akan dibangun dari berbagai segi. Fokus utama terletak pada kebutuhan untuk mendeteksi dini penyakit *Ganoderma* menggunakan pendekatan citra digital. Pada umumnya indeks vegetasi dapat lebih peka dalam menunjukkan tingkat kesehatan tanaman. Maka dari itu, penggunaan nilai-nilai indeks vegetasi diduga akan membantu deteksi tanaman sawit sakit dengan lebih baik.

3.2.1 Kebutuhan Pengguna

Pengguna dari sistem ini adalah pengelola kebun kelapa sawit yang memiliki kebutuhan untuk mendeteksi penyakit tanaman, khususnya *Ganoderma*, secara dini dan cepat. Deteksi yang dilakukan secara manual membutuhkan waktu yang lama dan tidak efisien jika harus dilakukan pada seluruh pohon di area kebun yang luas. Hal ini dapat menyebabkan keterlambatan dalam penanganan, sehingga pohon yang terinfeksi berisiko tumbang dan berdampak pada kerugian ekonomi.

Oleh karena itu, dibutuhkan sistem yang mampu melakukan deteksi secara otomatis dengan bantuan teknologi. Sistem ini harus dapat memberikan hasil yang cepat dan akurat untuk membantu pengambilan keputusan di lapangan, terutama dalam mengidentifikasi pohon-pohon yang berpotensi terinfeksi agar dapat segera ditindaklanjuti.

Dalam konteks penelitian ini, kebutuhan utama pengguna difokuskan pada pemilihan input terbaik yang dapat digunakan oleh sistem deteksi dini berbasis citra digital. Input yang dimaksud adalah indeks vegetasi berbasis RGB, yang diharapkan dapat merepresentasikan kondisi tanaman secara visual dan digunakan dalam proses identifikasi oleh model deteksi otomatis. Dengan demikian, hasil

penelitian ini diharapkan dapat mendukung pengembangan sistem yang lebih efektif dan sesuai dengan kebutuhan pengguna di lapangan.

3.2.2 Kebutuhan Peneliti

Berikut merupakan beberapa kebutuhan peneliti yang mencakup perangkat keras serta lunak:

1. Perangkat Keras

a. Laptop

- i. Prosesor: AMD Ryzen 3 3250U with Radeon Graphics 2.60 GHz
- ii. RAM: 8 GB
- iii. SSD: 512 GB
- iv. GPU: AMD Radeon Graphics
- v. Sistem Operasi: Windows 11 Home 64 bit

2. Perangkat Lunak

- a. Google Colaboratory
- b. Python
- c. QGIS
- d. NumPy
- e. PyTorch
- f. Matplotlib

3.3 Studi Literatur

Studi literatur dilakukan untuk memperoleh landasan teori dan wawasan yang relevan dalam mendukung proses analisis dan perancangan sistem deteksi dini penyakit *Ganoderma* pada kelapa sawit. Literatur yang dikaji berasal dari berbagai sumber, di antaranya jurnal ilmiah, artikel *website* terpercaya, dan laporan penelitian terdahulu, baik dari dalam maupun luar negeri.

Salah satu sumber penting yang digunakan dalam penelitian ini berasal dari penelitian terdahulu yang dilakukan oleh anggota Kelompok Riset *Precision Agriculture* (KRPA) Universitas Ma Chung. Penelitian-penelitian tersebut memberikan kontribusi besar dalam pengembangan teknologi berbasis citra digital untuk pertanian presisi, termasuk dalam pemanfaatan indeks vegetasi RGB untuk menganalisis kondisi tanaman. Beberapa studi dari KRPA juga telah mengkaji

penggunaan metode *machine learning* dan *deep learning* dalam konteks pertanian, yang menjadi referensi utama dalam pengembangan sistem pada penelitian ini.

Selain itu, jurnal-jurnal juga dijadikan referensi untuk memperkuat pemahaman terhadap metode yang digunakan, seperti *Convolutional Autoencoder* (CAE) dan penggunaan indeks vegetasi berbasis RGB seperti VARI, ExG, ExR, GLI, dan NGRDI. Literatur dari jurnal ini memberikan informasi teknis terkait performa masing-masing indeks serta implementasi model deteksi berbasis citra.

Sumber dari artikel dan website juga digunakan sebagai pelengkap informasi, terutama untuk mendapatkan data terbaru tentang industri kelapa sawit Indonesia, perkembangan teknologi deteksi dini di bidang pertanian, serta kondisi penyebaran penyakit *Ganoderma* pada kelapa sawit di Indonesia.

Dengan adanya studi literatur ini, diharapkan dapat menjadi dasar yang kuat dalam merancang sistem deteksi dini yang sesuai dengan kebutuhan lapangan, serta mendukung proses evaluasi dan analisis dalam menentukan input terbaik yang digunakan dalam model.

3.4 Persiapan Dataset

Citra awal yang akan digunakan berasal dari PT Perkebunan Nusantara (PTPN) berupa citra UAV dari kebun kelapa sawit. Citra tersebut diambil dengan jarak 500 meter dan menghasilkan citra beresolusi tinggi dengan ukuran 3 GB dalam format GeoTIFF dengan tiga kanal warna yaitu RGB.



Gambar 3. 2 Citra UAV kebun kelapa sawit

Langkah awal dalam proses persiapan dataset adalah pemilihan area citra yang akan digunakan untuk melatih model. Pemilihan area ini didasarkan pada keberadaan pohon kelapa sawit yang terindikasi sakit, agar proses pelabelan dan pelatihan model dapat lebih terfokus. Setelah area yang sesuai ditentukan, citra kemudian dipotong menjadi bagian-bagian yang lebih kecil dengan bentuk persegi atau persegi panjang sesuai kebutuhan analisis.

Selanjutnya, citra-citra hasil pemotongan tersebut dianotasi menggunakan platform Roboflow, di mana masing-masing pohon pada citra diberi label berdasarkan kondisinya, yaitu sehat atau sakit. Proses anotasi ini dilakukan secara manual untuk memastikan akurasi pelabelan. Setelah didapatkan label dari masing-masing pohon, citra akan dipotong kembali supaya menjadi citra per individu pohon.

Hasil dari tahapan ini adalah dataset yang terdiri dari citra individual pohon kelapa sawit beserta label kondisi masing-masing pohon. Dataset inilah yang nantinya digunakan sebagai input dalam pelatihan model deteksi dini penyakit

Ganoderma. Target jumlah individu pohon yang akan menjadi dataset ialah 400 pohon, terdiri dari 300 pohon sakit dan 100 pohon sehat.

3.5 Perancangan Model

Pada tahap ini akan dilakukan perancangan model *Convolutional Autoencoder* (CAE) yang akan digunakan untuk mendeteksi pohon kelapa sawit yang terindikasi terserang *Ganoderma*. Deteksi akan dilakukan dengan pendekatan deteksi anomali. Untuk itu, model dirancang untuk dapat merekonstruksi pohon sawit yang sehat.


Input yang digunakan pada pelatihan model pertama kali ialah hanya citra RGB. Citra akan di-*resize* menjadi ukuran yang seragam yakni 64×64 piksel. Selanjutnya, nilai intensitas RGB pada tiap-tiap piksel akan dinormalisasi ke dalam rentang 0 hingga 1. Dataset akan dibagi menjadi dua bagian yakni 80% citra sawit sehat sebagai data latih dan 20% kombinasi citra sawit sehat dan sakit sebagai data uji.

3.5.1 Arsitektur model 1

Arsitektur CAE yang dirancang memiliki dua bagian utama yakni *encoder* dan *decoder*. Arsitektur yang digunakan disusun berdasarkan studi sebelumnya oleh (Adinata, 2025). Pada bagian *encoder*, digunakan dua buah lapisan konvolusi. Input pada tahap ini ialah citra individu pohon kelapa sawit berukuran 64×64 piksel. Lapisan pertama memiliki 16 filter dengan ukuran kernel 3×3 untuk mengekstrak fitur-fitur penting dari citra, diikuti oleh fungsi aktivasi ReLU dan *max pooling* untuk mereduksi dimensi spasial citra. Selanjutnya, lapisan konvolusi kedua menggunakan 8 filter, juga dengan kernel 3×3 dan kembali diikuti oleh ReLU serta *max pooling*. Proses ini menghasilkan representasi laten dari input dengan ukuran yang lebih kecil namun tetap memuat informasi penting dari citra awal.

Representasi laten berupa array multidimensi yang dihasilkan pada tahap *encode* kemudian menjadi input pada tahap selanjutnya yakni *decode*. Pada bagian *decoder*, digunakan dua lapisan *transposed convolution* (*ConvTranspose2D*) yang bertugas untuk membangun kembali citra ke dalam bentuk yang menyerupai citra asli. Lapisan pertama melakukan *upsampling* dari 8 ke 16 channel, dan lapisan kedua mengembalikan ke 3 channel (RGB) untuk menghasilkan citra rekonstruksi

dengan ukuran dan format yang sama seperti input. Aktivasi sigmoid digunakan pada lapisan terakhir agar nilai piksel output berada dalam rentang 0 hingga 1.




Gambar 3. 3 Arsitekur CAE 1

Fungsi loss yang digunakan adalah *Mean Squared Error* (MSE), dengan optimizer Adam dan *learning rate* sebesar 0.001. Proses pelatihan dilakukan selama beberapa 50 *epoch* dengan *batch size* yang disesuaikan.

3.5.2 Arsitektur model 2

Arsitektur kedua yang digunakan didapat dari hasil modifikasi arsitektur pertama. Ukuran input yang digunakan masih tetap yakni 64×64 piksel dengan tiga *layer* warna. Pada bagian *encoder* digunakan tiga buah lapisan konvolusi. Lapisan konvolusi pertama memiliki 32 filter dengan ukuran kernel 3×3, diikuti dengan *max pooling* dan *dropout* sebesar 20% untuk mengurangi potensi *overfitting*. Kemudian dilanjutkan dengan lapisan konvolusi kedua yang memiliki 16 filter dengan ukuran kernel 3×3, kembali diikuti *max pooling* dan 20% *dropout*. Lapisan konvolusi ketiga memiliki 8 filter dengan ukuran kernel 3×3. Proses *encoding* ini kemudian menghasilkan representasi laten dari input untuk digunakan pada proses *decoding*.

Bagian *decoder* pada arsitektur ini menggunakan tiga buah lapisan *Conv2DTranspose*, diikuti dengan penambahan lapisan konvolusi untuk hasil rekonstruksi yang lebih tajam. Lapisan pertama melakukan *upsampling* ke 16 *channel* dengan kernel 3×3 serta diikuti dengan lapisan konvolusi dengan ukuran yang sama. Lapisan kedua menggunakan kernel 3×3, melakukan *upsampling* ke 32 *channel* dan kembali diikuti dengan lapisan konvolusi. Kemudian lapisan terakhir mengembalikan ukuran citra seperti semula dengan 3 *channel*.



Gambar 3. 4 Arsitektur CAE 2


Fungsi loss yang digunakan pada model kedua ini ialah *binary_crossentropy* dengan harapan deteksi detail fitur citra akan lebih halus. Pelatihan dilakukan sebanyak 50 *epoch*.

3.5.3 Arsitektur model 3

Arsitektur model ketiga disusun dengan lebih kompleks dengan harapan dapat meningkatkan efektivitasnya. Pada model ini, ukuran input yang digunakan ditingkatkan menjadi 128×128 piksel untuk memperhalus ekstraksi fitur citra. Bagian *encoder* pada model ini terdiri atas empat lapisan utama. Lapisan konvolusi pertama dengan 32 filter dan ukuran kernel 3×3 , diikuti dengan *batch normalization* untuk menjaga stabilitas proses pelatihan dan *max pooling* untuk mempertahankan fitur-fitur terpenting. Lapisan kedua dengan 64 filter, lapisan ketiga dengan 128 filter, dan diakhiri lapisan keempat dengan 256 filter, seluruhnya juga diikuti dengan *batch normalization* dan *max pooling*. Selanjutnya dilakukan proses *flattening* untuk mengubah bentuk data ke dalam satu dimensi agar dapat diproses lebih lanjut pada lapisan *dense*.

Representasi laten yang dihasilkan dari proses *encoding* masih berbentuk *dense layer*, sehingga tahap pertama *decoding* ialah mengembalikan dimensi data. Pada bagian *decoding* juga digunakan empat lapisan konvolusi, seluruhnya dengan ukuran kernel 3×3 . Lapisan pertama dengan 256 filter, lapisan kedua dengan 128

filter, lapisan ketiga dengan 64 filter, serta lapisan terakhir dengan 32 filter, seluruhnya diikuti dengan *batch normalization*. Selanjutnya bentuk data dikembalikan menjadi 3 *channel* sesuai dengan ukuran input.



Gambar 3. 5 Arsitektur CAE 3

Fungsi loss yang digunakan pada model ini ialah *Mean Squared Error* (MSE) dengan *optimizer* Adam. Proses pelatihan dilakukan sebanyak 50 *epoch*, namun dapat berhenti ketika nilai *loss* yang dihasilkan tidak lagi mengalami perubahan setelah 10 *epoch*.

3.6 Eksperimen Indeks Vegetasi

Setelah performa model dirasa cukup baik dalam melakukan deteksi dengan dataset input citra RGB, dilakukan eksperimen dengan indeks vegetasi. Eksperimen yang dimaksud ialah mengganti input pelatihan dan pengujian model yang semula berupa citra RGB menjadi indeks-indeks vegetasi yang meliputi *Visible*


Atmospherically Resistant Index (VARI), *Excess Green Index (ExG)*, *Excess Red Index (ExR)*, *Green Leaf Index (GLI)*, dan *Normalized Green-Red Difference Index (NGRDI)*. Indeks vegetasi pada umumnya lebih peka dalam mengukur tingkat kesehatan tanaman, sehingga eksperimen ini dilakukan dengan dugaan bahwa perubahan nilai dari RGB ke indeks vegetasi ini dapat meningkatkan kepekaan dalam mendeteksi anomali daun sawit.

Proses transformasi dilakukan dengan mengkonversi setiap citra RGB menjadi representasi dari masing-masing indeks menggunakan rumus matematis seperti pada subbab 2.4. Eksperimen ini dilakukan untuk mengevaluasi pengaruh masing-masing indeks terhadap kemampuan model dalam mendeteksi anomali pada citra. Setiap indeks diterapkan pada dataset yang sama, yaitu citra-citra pohon kelapa sawit yang telah dikumpulkan sebelumnya. Proses pelatihan model dan evaluasi dilakukan secara konsisten agar hasil yang diperoleh dapat dibandingkan secara objektif.

Berikut merupakan contoh perubahan citra dari RGB ke citra representasi masing-masing indeks vegetasi:



Gambar 3. 6 Citra RGB



Gambar 3. 7 Citra representasi indeks vegetasi

3.7 Analisis Perbandingan

Setelah proses pelatihan model selesai, termasuk didalamnya eksperimen dengan indeks-indeks vegetasi, selanjutnya dilakukan analisis untuk membandingkan dan mengevaluasi perbedaan performa model terhadap masing-masing input. Tujuan dilakukannya tahap ini ialah mengetahui sejauh mana

penggunaan indeks vegetasi dalam meningkatkan kemampuan model untuk merekonstruksi citra sebagai bagian dari proses deteksi *Ganoderma* pada kelapa sawit.

Perbandingan dilakukan dengan memperhatikan hasil evaluasi model berdasarkan metrik *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Learned Perceptual Image Patch Similarity* (LPIPS), *Structural Similarity Index Measure* (SSIM) dan *Feature Similarity Index* (FSIM). Metrik-metrik ini memberikan gambaran terkait kemampuan model dalam mempelajari pola visual dari citra-citra input serta merekonstruksinya seakurat mungkin. Nilai MAE, MSE dan LPIPS yang rendah mengindikasikan kesalahan atau *error* rekonstruksi yang kecil, sedangkan nilai SSIM dan FSIM yang tinggi menunjukkan kemiripan tinggi antara citra asal dengan citra hasil rekonstruksi. Dengan demikian, ketiga metrik ini menjadi indikator penting dalam menilai kinerja deteksi oleh model. Hasil dari proses analisis ini menjadi landasan penting dalam memahami kontribusi masing-masing indeks vegetasi dalam proses deteksi, sekaligus menentukan indeks mana yang paling optimal untuk digunakan sebagai input.

Setelah didapatkan nilai-nilai metrik untuk seluruh data uji, data akan dinilai kembali berdasarkan tingkat perbedaan distribusinya. Hal ini dilakukan untuk menilai apakah model berhasil memisahkan citra sawit yang sehat maupun yang sakit. Penilaian ini akan dilakukan dengan menghitung nilai *Jensen-Shannon Distance* (JSD) dan *Bhattacharyya Distance* (BD). Nilai JSD berkisar antara 0-1, di mana nilai yang semakin mendekati 1 mengindikasikan perbedaan bentuk distribusi yang signifikan. Sedangkan nilai BD dimulai dari 0 hingga tak hingga, di mana nilai yang lebih dari 1 berarti *overlap* antara kedua distribusi semakin kecil, atau dengan kata lain pemisahan data sangat optimal.


3.8 Penentuan

Berdasarkan hasil analisis perbandingan yang telah dilakukan, dapat dilakukan penentuan input terbaik untuk digunakan dalam model deteksi. Penentuan ini didasarkan pada nilai evaluasi yang dihasilkan oleh model ketika model dilatih dengan masing-masing input. Input yang menghasilkan performa terbaik ialah yang dapat menunjukkan perbedaan yang kontras pada citra pohon sehat dan sakit. Pada kasus pohon sehat, hal ini ditunjukkan dengan nilai MAE dan

MSE yang rendah, serta nilai SSIM yang tinggi karena menunjukkan kecilnya perbedaan antara citra asli dan rekonstruksi. Sebaliknya pada kasus pohon sakit, performa baik model ditunjukkan dengan nilai MAE dan MSE yang tinggi serta nilai SSIM yang rendah, karena menunjukkan adanya banyak perbedaan antara citra awal dengan citra hasil rekonstruksi.

3.9 Kesimpulan dan Rekomendasi

Dari seluruh proses yang telah dilakukan, akan ditarik kesimpulan yang berfokus pada pengaruh penggunaan indeks vegetasi terhadap kinerja model deteksi penyakit *Ganoderma* pada tanaman kelapa sawit, berikut dengan indeks vegetasi terbaik yang dapat dijadikan *input* model tersebut.




UNIVERSITAS
MA CHUNG

BAB IV


Hasil dan Pembahasan

4.1 Dataset

Sesuai penjelasan pada subbab 3.4, dilakukan pemilihan dan pemotongan sub area dari data awal. Pemotongan ini dilakukan pada platform QGIS dan menghasilkan sebuah gambar area yang lebih kecil berukuran tidak lebih dari 20 MB untuk menyesuaikan ukuran maksimal dari masukan platform Roboflow. Pada tahap ini, gambar yang sama disimpan dengan dua variasi yakni gambar area kebun polos serta gambar dengan tanda posisi pohon yang sakit.



Gambar 4. 1 Hasil pemotongan gambar dari QGIS




Gambar 4. 2 Hasil pemotongan gambar dari QGIS dengan tanda posisi pohon sakit

Gambar yang polos akan diproses lebih lanjut untuk memotong pohon per individu dengan platform Roboflow. Pemotongan dilakukan sekaligus dengan pelabelan gambar sakit dan sehat. Berkas citra disimpan dengan format penamaan yang diawali dengan “0_” untuk citra sakit, dan “1_” untuk citra sehat.

Dataset yang dihasilkan terdiri atas 300 citra tanaman sehat sebagai data latih, serta 100 citra tanaman sakit sebagai data uji. Seluruh citra disimpan dengan ukuran 64×64 piksel dengan format RGB.



Gambar 4. 3 Contoh citra sawit sehat (RGB)



Gambar 4. 4 Contoh citra sawit sakit (RGB)

Sebagai tahapan persiapan sebelum dilatih, dataset melalui proses *preprocessing* berupa normalisasi ke rentang nilai 0 – 1 untuk menjaga stabilitas kinerja model. Setelah itu gambar-gambar juga dipisahkan sesuai dengan keadaan sehat dan sakitnya sesuai dengan nama berkas. Hal ini dilakukan karena gambar sakit dan sehat pada awalnya tergabung dalam sebuah folder.


Sebagai gambaran awal sebelum masuk ke pemrosesan, disajikan visualisasi dalam bentuk histogram dari salah satu citra untuk melihat sebaran intensitas piksel pada citra pohon sehat dan sakit. Tujuan dari visualisasi ini ialah menunjukkan perbedaan distribusi warna pada kedua kondisi tanaman. Untuk citra RGB, histogram dibagi menjadi tiga buah yakni intensitas warna merah, hijau, dan biru. Kedua histogram disajikan dengan ditumpuk antara citra sehat dan sakit. Citra sehat diwakili dengan histogram berwarna biru, sedangkan citra sakit diwakili dengan histogram berwarna merah. Seluruh gambar yang dibandingkan pada tiap-tiap histogram merupakan gambar yang sama sebagai berikut:




Gambar 4. 5 Citra sehat untuk histrogram perbandingan




Gambar 4. 6 Citra sakit untuk histrogram perbandingan
dan histrogram perbandingan kedua citra tersebut adalah sebagai berikut:



Gambar 4. 7 Histogram perbandingan intensitas warna merah




Gambar 4. 8 Histogram perbandingan intensitas warna hijau




Gambar 4. 9 Histogram perbandingan intensitas warna biru

Pada citra RGB, tampak perbedaan sebaran warna merah, di mana pada gambar sakit intensitas warna merah tampak lebih besar. Pada warna hijau, terlihat area tumpang tindih yang besar antara kedua citra, namun pohon sehat memiliki intensitas warna hijau sedikit leboh rendah. Pada warna biru, pohon sehat memiliki intensitas yang cenderung lebih rendah dibandingkan pohon sakit.




Gambar 4. 10 Histogram perbandingan intensitas piksel VARI

Pada indeks vegetasi VARI, kedua distribusi mengalami tumpang tindih yang cukup besar. Namun dapat dilihat bahwa citra pohon sakit cenderung tersebar pada nilai yang lebih tinggi dibandingkan pohon sehat.




Gambar 4. 11 Histogram perbandingan intensitas piksel ExG

Pada indeks vegetasi ExG, histogram yang terbentuk cukup menunjukkan pemisahan data. Intensitas piksel pada citra sehat tampak lebih tinggi dibandingkan citra sakit.




Gambar 4. 12 Histogram perbandingan intensitas piksel ExR

Pada indeks vegetasi ExR, kedua histogram memiliki banyak area tumpang tindih, namun citra sakit cenderung berkumpul pada nilai-nilai yang lebih tinggi dibandingkan citra sehat.



Gambar 4. 13 Histogram perbandingan intensitas piksel GLI

Pada indeks vegetasi GLI, perbedaan intensitas kedua citra dapat terlihat dengan jelas, di mana citra sehat memiliki intensitas yang lebih tinggi dibandingkan citra sakit.



Gambar 4. 14 Histogram perbandingan intensitas piksel NGRDI


Pada indeks vegetasi NGRDI, perbandingan intensitas piksel pada kedua citra dapat terlihat dengan cukup jelas, di mana citra sehat memiliki nilai-nilai yang lebih tinggi dibandingkan dengan citra sakit.

4.2 Preprocessing Citra Input

Seluruh citra RGB yang terkumpul kemudian diekstraksi ke dalam indeks-indeks vegetasi seperti tercantum pada subbab 2.4. Hasil ekstraksi berupa citra *grayscale* yang merepresentasikan nilai indeks vegetasi pada setiap piksel.

4.2.1 Dataset VARI

Indeks vegetasi VARI dengan nilai yang tinggi digambarkan dengan piksel yang lebih cerah atau mendekati warna putih. Representasi indeks VARI yang terang menandakan banyak ditemukan warna hijau pada gambar.



Gambar 4. 15 Contoh citra sawit sehat (VARI)



Gambar 4. 16 Contoh citra sawit sakit (VARI)

4.2.2 Dataset ExG

Indeks vegetasi ExG dapat menunjukkan tingkat kehijauan pada gambar. Interpretasinya mirip dengan VARI, yakni semakin tinggi nilai ExG, semakin cerah visualisasinya, maka dominasi warna hijau semakin kuat pada gambar.



Gambar 4. 17 Contoh citra sawit sehat (ExG)



Gambar 4. 18 Contoh citra sawit sakit (ExG)

4.2.3 Dataset ExR

Indeks vegetasi ExR berfokus pada warna merah yang terdapat pada gambar. Gambar yang didominasi warna merah dapat mengindikasikan daun yang kering. Warna merah sendiri pada indeks ExR ditandai dengan yang tinggi dan visualisasi warna yang terang.




Gambar 4. 19 Contoh citra sawit sehat (ExR)



Gambar 4. 20 Contoh citra sawit sakit (ExR)

4.2.4 Dataset GLI

Indeks vegetasi GLI dapat menunjukkan tingkat kesehatan daun dengan mengukur tingkat kehijauan pada gambar. Nilai GLI yang tinggi direpresentasikan dengan warna yang lebih terang dapat berarti banyak daun sehat berwarna hijau pada gambar. Sebaliknya, daerah yang lebih gelap berarti lebih sedikit warna hijau.



Gambar 4. 21 Contoh citra sawit sehat (GLI)



Gambar 4. 22 Contoh citra sawit sakit (GLI)

4.2.5 Dataset NGRDI

Indeks NGRDI dapat menunjukkan tingkat kesehatan tanaman dengan membandingkan antara warna hijau dan merah pada gambar. Nilai NGRDI yang tinggi direpresentasikan dengan warna terang berarti daerah tersebut lebih didominasi warna hijau ketimbang merah. Sebaliknya, nilai NGRDI yang rendah mengindikasikan lebih banyak warna merah pada gambar.



Gambar 4. 23 Contoh citra sawit sehat (NGRDI)



Gambar 4. 24 Contoh citra sawit sakit (NGRDI)

4.3 Arsitektur Model Autoencoder

Model yang digunakan pada penelitian ini adalah *Convolutional Autoencoder* yang dirancang untuk mempelajari fitur-fitur utama dari citra sawit sehat untuk kemudian mendeteksi anomali pada citra sawit yang sakit. Deteksi anomali dilakukan dengan menghitung selisih hasil rekonstruksi yang dinilai dengan metrik-metrik berikut: *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), *Learned Perceptual Image Patch Similarity* (LPIPS), *Structural Similarity Index Measure* (SSIM) dan *Feature Similarity Index* (FSIM). Arsitektur yang digunakan berjumlah tiga buah, ketiganya dibangun menggunakan pustaka Keras dari Python. Masing-masing arsitektur akan dilatih dengan enam jenis data input, yaitu RGB, VARI, ExG, ExR, GLI, dan NGRDI.

4.3.1 Model 1

Model yang pertama disusun berdasarkan subbab 3.5. Ukuran gambar yang digunakan pada model ini adalah $64 \times 64 \times 3$ untuk input RGB, dan $64 \times 64 \times 1$ untuk input indeks vegetasi.

Tabel 4. 1 Arsitektur *encoder* model 1

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None , 64, 64, 3)	0
conv2d (Conv2D)	(None , 64, 64, 16)	448
max_pooling2d (MaxPooling2D)	(None , 32, 32, 16)	0
conv2d_1 (Conv2D)	(None , 32, 32, 8)	1,160
max_pooling2d_1 (MaxPooling2D)	(None , 16, 16, 8)	0

Tabel 4. 2 Arsitektur *decoder* model 1

Layer (type)	Output Shape	Param #
input_layer (<i>InputLayer</i>)	(None, 16, 16, 8)	0
conv2d_transpose (<i>Conv2DTranspose</i>)	(None, 32, 32, 16)	1,168
conv2d_transpose_1 (<i>Conv2DTranspose</i>)	(None, 64, 64, 3)	435

4.3.2 Model 2

Model kedua disusun berdasarkan modifikasi dari model pertama. Perubahan dilakukan dengan tujuan untuk meningkatkan kemampuan deteksi anomali secara lebih sensitif dan akurat. Salah satu modifikasi utama adalah pengecilan ruang laten dari dimensi $16 \times 16 \times 8$ menjadi $8 \times 8 \times 8$. Dengan representasi yang lebih padat, model diharapkan dapat lebih responsif terhadap perbedaan kecil yang menjadi indikasi anomali.

Selain itu, ditambahkan teknik regularisasi berupa *Dropout* dan *L2 regularization* pada bagian *encoder* untuk mengurangi risiko *overfitting*. *Loss function* juga diubah dari *Mean Squared Error* (MSE) menjadi *Binary Crossentropy* (BCE), yang dianggap lebih efektif dalam membedakan nilai piksel pada citra biner atau bernormalisasi antara 0 hingga 1.

Bagian *decoder* juga mengalami perubahan dengan penambahan *layer* konvolusi di antara proses dekonvolusi (*Conv2DTranspose*), sehingga hasil rekonstruksi dapat menjadi lebih tajam dan mendekati citra asli.

Ukuran gambar yang digunakan pada model kedua tidak berubah dari model pertama.

Tabel 4. 3 Arsitektur *encoder* model 2

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 64, 64, 3)	0
conv2d (Conv2D)	(None, 64, 64, 32)	896
max_pooling2d (MaxPooling2D)	(None, 32, 32, 32)	0
dropout (Dropout)	(None, 32, 32, 32)	0
conv2d_1 (Conv2D)	(None, 32, 32, 16)	4,624
max_pooling2d_1 (MaxPooling2D)	(None, 16, 16, 16)	0
dropout_1 (Dropout)	(None, 16, 16, 16)	0
conv2d_2 (Conv2D)	(None, 16, 16, 8)	1,160
max_pooling2d_2 (MaxPooling2D)	(None, 8, 8, 8)	0

Tabel 4. 4 Arsitektur *decoder* model 2

Layer (type)	Output Shape	Param #
input_layer_1 (InputLayer)	(None, 8, 8, 8)	0
conv2d_transpose (Conv2DTranspose)	(None, 16, 16, 16)	1,168
conv2d_3 (Conv2D)	(None, 16, 16, 16)	2,320
conv2d_transpose_1 (Conv2DTranspose)	(None, 32, 32, 32)	4,640
conv2d_4 (Conv2D)	(None, 32, 32, 32)	9,248
conv2d_transpose_2 (Conv2DTranspose)	(None, 64, 64, 16)	4,624
conv2d_5 (Conv2D)	(None, 64, 64, 3)	435

4.3.3 Model 3

Model ketiga merupakan model tambahan yang disusun untuk eksperimen lanjutan terhadap performa arsitektur model *Convolutional Autoencoder*. Perbedaan pertama terletak pada ukuran gambar yang digunakan yakni 128×128 piksel, baik untuk citra RGB (3 saluran) maupun indeks vegetasi (1 saluran). Bagian *encoder* model ini terdiri atas empat lapisan konvolusi yang diikuti oleh *Batch Normalization* dan *MaxPooling2D*, dan hasil ekstraksi fitur dikompresi ke dalam ruang laten berdimensi 64 menggunakan *layer Dense*. Bagian *decoder* dibangun dengan empat lapisan *Conv2DTranspose*, *Batch Normalization*, dan *UpSampling2D*, kemudian diakhiri dengan *layer Conv2D* beraktivasi sigmoid untuk merekonstruksi citra.

Tabel 4. 5 Arsitektur *encoder* model 3

Layer (type)	Output Shape	Param #
encoder_input (InputLayer)	(None , 128, 128, 3)	0
conv2d (Conv2D)	(None , 128, 128, 32)	896
batch_normalization (BatchNormalization)	(None , 128, 128, 32)	128
max_pooling2d (MaxPooling2D)	(None , 64, 64, 32)	0
conv2d_1 (Conv2D)	(None , 64, 64, 64)	18,496
batch_normalization_1 (BatchNormalization)	(None , 64, 64, 64)	256
max_pooling2d_1 (MaxPooling2D)	(None , 32, 32, 64)	0
conv2d_2 (Conv2D)	(None , 32, 32, 128)	73,856
batch_normalization_2 (BatchNormalization)	(None , 32, 32, 128)	512
max_pooling2d_2 (MaxPooling2D)	(None , 16, 16, 128)	0
conv2d_3 (Conv2D)	(None , 16, 16, 256)	295,168
batch_normalization_3 (BatchNormalization)	(None , 16, 16, 256)	1,024
max_pooling2d_3 (MaxPooling2D)	(None , 8, 8, 256)	0
flatten (Flatten)	(None , 16384)	0
encoded (Dense)	(None , 64)	1,048,640

UNIVERSITAS
MA CHUNG

Tabel 4. 6 Arsitektur *decoder* model 3

Layer (type)	Output Shape	Param #
decoder_input (InputLayer)	(None, 64)	0
dense (Dense)	(None, 16384)	1,064,960
reshape (Reshape)	(None, 8, 8, 256)	0
conv2d_transpose (Conv2DTranspose)	(None, 8, 8, 256)	590,080
batch_normalization_4 (BatchNormalization)	(None, 8, 8, 256)	1,024
up_sampling2d (UpSampling2D)	(None, 16, 16, 256)	0
conv2d_transpose_1 (Conv2DTranspose)	(None, 16, 16, 128)	295,040
batch_normalization_5 (BatchNormalization)	(None, 16, 16, 128)	512
up_sampling2d_1 (UpSampling2D)	(None, 32, 32, 128)	0
conv2d_transpose_2 (Conv2DTranspose)	(None, 32, 32, 64)	73,792
batch_normalization_6 (BatchNormalization)	(None, 32, 32, 64)	256
up_sampling2d_2 (UpSampling2D)	(None, 64, 64, 64)	0
conv2d_transpose_3 (Conv2DTranspose)	(None, 64, 64, 32)	18,464
batch_normalization_7 (BatchNormalization)	(None, 64, 64, 32)	128
up_sampling2d_3 (UpSampling2D)	(None, 128, 128, 32)	0
decoded (Conv2D)	(None, 128, 128, 3)	867

4.4 Hasil Pelatihan Model Autoencoder

Ketiga arsitektur yang telah disusun kemudian dilatih dengan enam kelompok data, yakni RGB, VARI, ExG, ExR, GLI, dan NGRDI. Seluruh model dilatih hingga 50 *epoch*. Proses pelatihan ini menghasilkan grafik *loss function* yang merepresentasikan kemampuan model dalam merekonstruksi citra input. Nilai *loss* yang rendah mengindikasikan keberhasilan model dalam merekonstruksi citra, begitupun sebaliknya nilai *loss* yang tinggi menunjukkan kesalahan atau kegagalan dalam rekonstruksi citra. Grafik *loss* dapat menjadi langkah awal dalam evaluasi kemampuan model mengenali fitur-fitur utama citra sawit sehat.


Pada ketiga model, masing-masing grafik yang dihasilkan terdiri dari dua kurva yang menjadi indikator kinerja model, yakni kurva berwarna biru untuk nilai *loss training* atau pelatihan, sedangkan kurva berwarna oranye untuk *loss validasi*.

Model yang dinilai memiliki performa baik adalah model yang menghasilkan grafik dengan kedua kurva tersebut saling berdekatan atau berimpitan. Hal ini menunjukkan bahwa model terlatih dengan baik untuk mempelajari karakteristik data input yang diberikan, sekaligus mampu mengenali data serupa yang belum pernah ditemukan sebelumnya.


Ketika kondisi kedua kurva berdekatan tidak terpenuhi, ada kemungkinan terjadinya kondisi *overfitting* atau *underfitting*. *Overfitting* ditandai dengan hasil *loss training* yang bernilai kecil, sedangkan *loss validasi* masih tinggi. Kondisi ini berarti model terlalu mempelajari data latih sehingga tidak mampu mengenali data baru secara general. Sedangkan *underfitting* ditandai dengan kedua kurva yang tetap menunjukkan nilai tinggi setelah proses pelatihan. Hal ini berarti model tidak mampu mengenali fitur-fitur penting pada data yang mengakibatkan generalisasinya juga tidak optimal.

4.4.1 Model 1


Model pertama menggunakan *Convolutional Autoencoder* dengan arsitektur dasar dan menggunakan *Mean Squared Error* (MSE) sebagai *loss function*. Model ini dilatih pada seluruh kelompok input dan mampu menunjukkan performa yang cukup stabil.




Gambar 4. 25 Grafik *loss* model 1 input RGB




Gambar 4. 26 Grafik *loss* model 1 input VARI




Gambar 4. 27 Grafik *loss* model 1 input ExG



Gambar 4. 28 Grafik *loss* model 1 input ExR




Gambar 4. 29 Grafik *loss* model 1 input GLI




Gambar 4. 30 Grafik *loss* model 1 input NGRDI

Seperti disajikan pada gambar 4.19 – 4.24, model 1 menghasilkan grafik *loss* yang stabil, yang berarti proses pelatihan berlangsung dengan baik. Kurva berwarna biru yang menunjukkan *loss training* nampak berangsur turun secara teratur, mengindikasikan bahwa model semakin lama semakin memahami karakteristik data. Begitupun dengan kurva *loss validasi* yang selalu berjalan sejajar dengan *training*, menandakan model memiliki kemampuan yang baik dalam mengenali pola-pola dari data baru.


Untuk melengkapi pemaparan performa model pertama tersebut, disajikan pula visualisasi perubahan citra dari citra awal menjadi citra hasil rekonstruksi.




Gambar 4. 31 Hasil rekonstruksi model 1 – RGB




Gambar 4. 32 Hasil rekonstruksi model 1 – VARI




Gambar 4. 33 Hasil rekonstruksi model 1 – ExG



Gambar 4. 34 Hasil rekonstruksi model 1 – ExR




Gambar 4. 35 Hasil rekonstruksi model 1 – GLI




Gambar 4. 36 Hasil rekonstruksi model 1 – NGRDI

4.4.2 Model 2


Model kedua merupakan varian dari model pertama yang menggunakan *Binary Crossentropy* (BCE) sebagai loss function. Penggunaan BCE ditujukan untuk memperkuat kemampuan model dalam membedakan detail piksel secara lebih tajam. Model ini juga diuji menggunakan keenam jenis input untuk membandingkan sensitivitas terhadap perbedaan nilai piksel antar kategori sehat dan sakit.




Gambar 4. 37 Grafik *loss* model 2 input RGB




Gambar 4. 38 Grafik *loss* model 2 input VARI




Gambar 4. 39 Grafik *loss* model 2 input ExG



Gambar 4. 40 Grafik *loss* model 2 input ExR




Gambar 4. 41 Grafik *loss* model 2 input GLI




Gambar 4. 42 Grafik *loss* model 2 input NGRDI

Model kedua memiliki hasil pelatihan yang beragam. Pada pelatihan dengan data citra VARI, GLI, dan NGRDI, model menghasilkan grafik yang stabil antara nilai *loss training* dan validasinya. Sedangkan pada data RGB, ExG, dan ExR, model menghasilkan kurva *loss training* yang baik, namun terjadi fluktuasi nilai pada *loss validasi*. Kondisi ini cenderung mengarah pada *overfitting*, yang menandakan model belum memiliki kemampuan yang baik dalam mengenali data baru ketika dilatih dengan ketiga dataset ini.


Untuk melengkapi pemaparan performa model kedua tersebut, disajikan pula visualisasi perubahan citra dari citra awal menjadi citra hasil rekonstruksi.




Gambar 4. 43 Hasil rekonstruksi model 2 – RGB




Gambar 4. 44 Hasil rekonstruksi model 2 – VARI




Gambar 4. 45 Hasil rekonstruksi model 2 – ExG



Gambar 4. 46 Hasil rekonstruksi model 2 – ExR




Gambar 4. 47 Hasil rekonstruksi model 2 – GLI




Gambar 4. 48 Hasil rekonstruksi model 2 – NGRDI

4.4.3 Model 3


Model ketiga dengan arsitektur paling kompleks diantara model lainnya, kembali menggunakan *Mean Squared Error* (MSE) sebagai *loss function*. Hal ini dilakukan untuk menemukan pengaruh kompleksitas arsitektur terhadap kinerja model. Meskipun dirancang untuk tetap dilatih hingga 50 *epoch*, model ketiga diatur dapat berhenti melatih ketika hasil *loss* tidak lagi mengalami perubahan selama 10 *epoch* terakhir, sehingga pelatihan dapat berhenti sebelum mencapai *epoch* ke 50. Hasil dari pelatihan model ketiga menunjukkan dominasi keadaan *overfitting* pada sebagian besar kelompok input.




Gambar 4. 49 Grafik *loss* model 3 input RGB




Gambar 4. 50 Grafik *loss* model 3 input VARI




Gambar 4. 51 Grafik *loss* model 3 input ExG



Gambar 4. 52 Grafik *loss* model 3 input ExR



Gambar 4. 53 Grafik *loss* model 3 input GLI




Gambar 4. 54 Grafik *loss* model 3 input NGRDI

Kondisi *overfitting* dapat dilihat secara jelas pada grafik yang dihasilkan. Pada kelompok input ExG dan ExR, hasil kedua kurva menunjukkan jarak yang paling jauh. Diikuti dengan kelompok input RGB, VARI, dan GLI yang juga terpisah namun tidak sejauh ExG dan ExR. Sedangkan pada kelompok input NGRDI, jarak pada akhir *epoch* tidak berbeda jauh namun terjadi lonjakan nilai *loss* validasi pada awal *epoch* yang cukup tinggi.


Untuk melengkapi pemaparan performa model ketiga tersebut, disajikan pula visualisasi perubahan citra dari citra awal menjadi citra hasil rekonstruksi.




Gambar 4. 55 Hasil rekonstruksi model 3 – RGB




Gambar 4. 56 Hasil rekonstruksi model 3 – VARI




Gambar 4. 57 Hasil rekonstruksi model 3 – ExG



Gambar 4. 58 Hasil rekonstruksi model 3 – ExR



Gambar 4. 59 Hasil rekonstruksi model 3 – GLI



Gambar 4. 60 Hasil rekonstruksi model 3 – NGRDI

4.5 Perbandingan Kinerja Model berdasarkan Input

Model yang telah dilatih kemudian diuji dengan citra sawit yang sakit. Tujuan dari tahap ini ialah mengukur kemampuan model dalam mendeteksi anomali, dengan mengamati perbedaan antara citra input dengan citra hasil rekonstruksi. Perbandingan dilakukan dengan menghitung beberapa metrik evaluasi yang dapat mengukur tingkat ketidakcocokan visual antara keduanya. Metrik-metrik yang digunakan antara lain *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), *Learned Perceptual Image Patch Similarity* (LPIPS),

Structural Similarity Index Measure (SSIM) dan *Feature Similarity Index* (FSIM). Pada penelitian ini, tingkat kemampuan rekonstruksi yang buruk menunjukkan keberhasilan deteksi anomali. Hal ini diindikasikan dengan nilai MSE, MAE, dan LPIPS yang tinggi, dan sebaliknya nilai SSIM dan FSIM yang rendah.

Hasil penghitungan metrik antara citra sehat dan sakit kemudian dibandingkan. Perbandingan disajikan secara visual dalam bentuk histogram untuk mempermudah interpretasi hasil. Histogram terdiri dari dua kelompok, yakni kelompok citra sehat yang berwarna biru, dan kelompok citra sakit yang berwarna merah. Sumbu x pada histogram menunjukkan nilai hasil penghitungan metrik yang didapatkan, sedangkan sumbu y menunjukkan frekuensi dari nilai tersebut. Bentuk distribusi data antara hasil penghitungan metrik pada citra sehat dan sakit kemudian kembali dibandingkan dengan dua nilai, yakni *Jensen-Shannon Divergence* (JSD), dan *Bhattacharyya Distance* (BD). Kedua nilai ini digunakan untuk mengukur jarak distribusi antara dua kelompok data, sehingga dapat menjadi indikator seberapa tajam perbedaan karakteristik yang ditangkap model.

Nilai JSD memiliki rentang dari 0 hingga 1, di mana nilai yang mendekati 0 menunjukkan bahwa kedua distribusi sangat mirip, sedangkan nilai mendekati 1 menunjukkan perbedaan yang sangat besar. Sebagai acuan interpretasi, nilai $JSD < 0.1$ dianggap sangat mirip, $0.1 - 0.3$ sedikit berbeda, dan > 0.3 menunjukkan perbedaan yang signifikan (Pawar, 2025). Sementara itu BD bernilai antara 0 dan tak hingga, dengan interpretasi nilai $BD < 0.1$ dianggap sangat mirip atau *overlap* diagram besar, $0.1 - 0.5$ sedikit berbeda, $0.5 - 1$ cukup berbeda, dan BD lebih dari 1 sangat berbeda (Avneon, 2023). Nilai yang lebih besar menunjukkan bahwa distribusi antara citra sehat dan sakit semakin jauh, yang berarti model berhasil membedakan keduanya dengan baik.


4.5.1 Model 1

Pada bagian ini ditampilkan hasil evaluasi performa Model 1 terhadap seluruh kelompok input (RGB dan indeks vegetasi). Fokus evaluasi diarahkan pada efektivitas model dalam membedakan citra sehat dan sakit berdasarkan selisih rekonstruksi yang diukur menggunakan metrik visual dan distribusi.


1. Input RGB

Nilai JSD pada eksperimen ini cukup menunjukkan perbedaan distribusi, namun menunjukkan juga masih adanya *overlap* pada tiap-tiap distribusi berdasarkan nilai BD yang dihasilkan. Pada model pertama dengan input RGB ini, metrik MAE dan LPIPS mampu menunjukkan perbedaan bentuk distribusi paling signifikan, diikuti dengan SSIM dan FSIM dengan sedikit perbedaan, serta MSE yang menunjukkan kemiripan antara kedua distribusi.

Model 1 - RGB



Gambar 4. 61 Grafik hasil pengujian model 1 input RGB




Gambar 4. 62 Diagram frekuensi kategori nilai JSD model 1 input RGB

2. Input VARI


Model pertama yang dilatih dengan dataset VARI menunjukkan bentuk distribusi data yang berbeda, terlebih pada metrik SSIM dan FSIM. Nilai BD yang dihasilkan menunjukkan adanya sedikit *overlap* antara kedua nilai, namun kembali dapat dipisahkan dengan cukup baik pada metrik SSIM dan FSIM.

UNIVERSITAS
MA CHUNG

Model 1 - VARI



Gambar 4. 63 Grafik hasil pengujian model 1 input VARI




Gambar 4. 64 Diagram frekuensi kategori nilai JSD model 1 input VARI

3. Input ExG


Model pertama yang dilatih dengan dataset ExG cenderung gagal dalam menunjukkan perbedaan distribusi nilai metrik antara citra sehat dan sakit. Hal ini dapat dilihat dari visualisasi berupa grafik serta nilai JSD dan BD yang cenderung mendekati 0, khususnya pada metrik MSE dan MAE. Pada eksperimen ini banyak ditemukan *overlap* nilai pada sebagian besar metrik.

UNIVERSITAS
MA CHUNG

Model 1 - EXG



Gambar 4. 65 Grafik hasil pengujian model 1 input ExG




Gambar 4. 66 Diagram frekuensi kategori nilai JSD model 1 input ExG

4. Input ExR


Model pertama yang dilatih dengan dataset ExR menunjukkan adanya perbedaan pada distribusi nilai ketika diukur dengan metrik FSIM, namun tidak berbeda signifikan ketika diukur dengan metrik lainnya. Kedua distribusi juga selalu mengalami *overlap* yang dapat dilihat dari nilai BD yang dihasilkan.

UNIVERSITAS
MA CHUNG

Model 1 - EXR



Gambar 4. 67 Grafik hasil pengujian model 1 input ExR




Gambar 4. 68 Diagram frekuensi kategori nilai JSD model 1 input ExR

5. Input GLI


Model pertama yang dilatih dengan dataset GLI metrik menunjukkan adanya perbedaan signifikan antara kedua distribusi ketika diukur dengan metrik SSIM dan FSIM, namun tetap mengalami *overlap* antara kedua nilai. Pemisahan terbaik dapat ditemukan pada metrik FSIM.

UNIVERSITAS
MA CHUNG

Model 1 - GLI



Gambar 4. 69 Grafik hasil pengujian model 1 input GLI




Gambar 4. 70 Diagram frekuensi kategori nilai JSD model 1 input GLI

6. Input NGRDI


Model pertama yang dilatih dengan dataset NGRDI cukup menunjukkan perbedaan signifikan pada metrik SSIM dan FSIM, namun menunjukkan kemiripan ketika diukur dengan metrik MSE. Nilai BD yang dihasilkan menunjukkan bahwa kedua distribusi mulai terpisah namun belum optimal.

UNIVERSITAS
MA CHUNG

Model 1 - NGRDI



Gambar 4. 71 Grafik hasil pengujian model 1 input NGRDI



Gambar 4. 72 Diagram frekuensi kategori nilai JSD model 1 input NGRDI

Untuk mengevaluasi kinerja masing-masing indeks vegetasi pada model pertama ini, disajikan nilai rata-rata dari JSD dan BD yang diperoleh.

Tabel 4. 7 Rata-rata JSD dan BD per indeks vegetasi model 1

Model	Input	JSD	BD
Model 1	RGB	0.2581	0.3451
	VARI	0.3323	0.3365
	ExG	0.1479	0.1574
	ExR	0.1849	0.2247
	GLI	0.2879	0.3575
	NGRDI	0.2666	0.2667

Tabel 4.7 memperlihatkan kinerja indeks VARI dengan nilai JSD 0.3323 adalah yang terbaik dibandingkan indeks lainnya dalam menonjolkan perbedaan bentuk distribusi data, sedangkan indeks GLI dengan nilai BD 0.3575 bekerja paling optimal dalam pemisahan data.


4.5.2 Model 2

Model 2 juga dibandingkan terhadap keenam kelompok input menggunakan metrik yang sama. Tujuan analisis ini adalah untuk melihat bagaimana arsitektur dan *loss function* yang berbeda memengaruhi sensitivitas deteksi terhadap perubahan visual pada citra sakit.


1. Input RGB

Model kedua yang dilatih dengan input secara umum RGB dapat menunjukkan perbedaan distribusi signifikan ketika diukur dengan metrik MAE, namun menunjukkan perbedaan ringan pada metrik lainnya. Nilai BD yang rendah menunjukkan area *overlap* data masih cukup besar pada seluruh metrik.

Model 2 - RGB



Gambar 4. 73 Grafik hasil pengujian model 2 input RGB




Gambar 4. 74 Diagram frekuensi kategori nilai JSD model 2 input RGB

2. Input VARI


Model kedua yang dilatih dengan dataset VARI menunjukkan distribusi yang cenderung berbeda pada sebagian besar metrik, terlebih SSIM dan FSIM, serta mulai menunjukkan pemisahan data yang baik berdasarkan nilai BD yang dihasilkan.

UNIVERSITAS
MA CHUNG

Model 2 - VARI



Gambar 4. 75 Grafik hasil pengujian model 2 input VARI




Gambar 4. 76 Diagram frekuensi kategori nilai JSD model 2 input VARI

3. Input ExG


Model kedua yang dilatih dengan dataset ExG menunjukkan dominasi nilai JD cukup tinggi yang mengindikasikan perbedaan antara kedua distribusi, khususnya pada metrik SSIM dan FSIM. Namun tetap ada area *overlap* antara keduanya secara konsisten di seluruh metrik.

UNIVERSITAS
MA CHUNG

Model 2 - EXG



Gambar 4. 77 Grafik hasil pengujian model 2 input ExG




Gambar 4. 78 Diagram frekuensi kategori nilai JSD model 2 input ExG

4. Input ExR


Model kedua yang dilatih dengan dataset ExR menunjukkan nilai JSD cukup tinggi ketika diukur dengan metrik SSIM dan FSIM, yang berarti terdapat perbedaan bentuk distribusi yang signifikan. Sedangkan seluruh metrik menghasilkan nilai BD yang cenderung rendah yang mengindikasikan besarnya area *overlap* pada kedua distribusi.

UNIVERSITAS
MA CHUNG

Model 2 - EXR



Gambar 4. 79 Grafik hasil pengujian model 2 input ExR




Gambar 4. 80 Diagram frekuensi kategori nilai JSD model 2 input ExR

5. Input GLI


Model kedua yang dilatih dengan dataset GLI sebagian besar menunjukkan adanya perbedaan antara kedua bentuk distribusi, terutama pada metrik SSIM dan FSIM, namun dengan pemisahan data yang belum optimal pada seluruh metrik.

UNIVERSITAS
MA CHUNG

Model 2 - GLI



Gambar 4. 81 Grafik hasil pengujian model 2 input GLI




Gambar 4. 82 Diagram frekuensi kategori nilai JSD model 2 input GLI

6. Input NGRDI


Model kedua yang dilatih dengan dataset NGRDI cukup menunjukkan adanya perbedaan antara kedua distribusi, khususnya ketika diukur dengan metrik SSIM dan FSIM. Eksperimen ini cukup menunjukkan pemisahan data yang optimal terutama pada metrik SSIM.

UNIVERSITAS
MA CHUNG

Model 2 - NGRDI



Gambar 4. 83 Grafik hasil pengujian model 2 input NGRDI



Gambar 4. 84 Diagram frekuensi kategori nilai JSD model 2 input NGRDI

Untuk membantu penilaian kinerja masing-masing indeks vegetasi sebagai input pada model kedua, disajikan tabel nilai rata-rata JSD dan BD yang diperoleh.

Tabel 4. 8 Rata-rata JSD dan BD per indeks vegetasi model 2

Model	Input	JSD	BD
Model 2	RGB	0.2134	0.1562
	VARI	0.3216	0.3873
	ExG	0.2649	0.1679
	ExR	0.2346	0.1408
	GLI	0.2783	0.2191
	NGRDI	0.3258	0.3157

Pada tabel 4.8 terlihat kinerja indeks NGRDI dengan nilai JSD 0.358 unggul dalam menunjukkan perbedaan bentuk distribusi data, serta VARI dengan nilai BD 0.3873 unggul dalam pemisahan area *overlapping* data.

4.5.3 Model 3

Seperti dua model sebelumnya, Model 3 diuji pada seluruh kelompok input untuk mengukur performa deteksinya. Evaluasi difokuskan pada identifikasi input yang menghasilkan hasil paling stabil dalam mendeteksi anomali pada pohon sakit. Namun sebagian besar hasil pelatihan model ketiga menunjukkan terjadinya *overfitting*, ditandai dengan perbedaan signifikan antara *loss* pada data pelatihan dan validasi. Kondisi ini menyulitkan interpretasi performa model secara akurat,


sehingga penilaian terhadap efektivitas input menjadi kurang meyakinkan dibandingkan dua model sebelumnya.

1. Input RGB


Model kedua yang dilatih dengan data RGB mampu menunjukkan perbedaan distribusi yang signifikan pada metrik SSIM dan FSIM, sedangkan sedikit berbeda pada metrik lainnya. Namun untuk nilai masing-masing metrik masih terlihat kemiripan nilai antara citra sakit dan sehat, terlihat dari nilai BD yang dihasilkan cenderung rendah.



Model 3 - RGB



Gambar 4. 85 Grafik hasil pengujian model 3 input RGB




Gambar 4. 86 Diagram frekuensi kategori nilai JSD model 3 input RGB

2. Input VARI


Model ketiga yang dilatih dengan citra VARI menunjukkan perbedaan yang cukup signifikan pada distribusi metrik, terutama pada metrik LPIPS, SSIM dan FSIM. Nilai BD secara konsisten menunjukkan masih adanya *overlap* data pada seluruh metrik.

UNIVERSITAS
MA CHUNG

Model 3 - VARI



Gambar 4. 87 Grafik hasil pengujian model 3 input VARI




Gambar 4. 88 Diagram frekuensi kategori nilai JSD model 3 input VARI

3. Input ExG


Model ketiga yang dilatih dengan input ExG menunjukkan sangat sedikit perbedaan distribusi pada seluruh metrik, ditambah dengan area *overlap* data yang besar sehingga pemisahan belum optimal.

UNIVERSITAS
MA CHUNG

Model 3 - EXG



Gambar 4. 89 Grafik hasil pengujian model 3 input ExG




Gambar 4. 90 Diagram frekuensi kategori nilai JSD model 3 input ExG

4. Input ExR


Model ketiga yang dilatih dengan citra ExR menunjukkan perbedaan signifikan antara kedua bentuk distribusi pada metrik MAE, SSIM dan FSIM, serta sedikit perbedaan pada metrik-metrik lainnya, namun dengan tingkat pemisahan data masih rendah yang ditunjukkan dengan dominasi nilai BD rendah.

UNIVERSITAS
MA CHUNG

Model 3 - EXR



Gambar 4. 91 Grafik hasil pengujian model 3 input ExR




Gambar 4. 92 Diagram frekuensi kategori nilai JSD model 3 input ExR

5. Input GLI


Model ketiga yang dilatih menggunakan citra GLI cukup baik menunjukkan adanya perbedaan pada distribusi, khususnya pada metrik LPIPS, SSIM dan FSIM meskipun *overlap* kedua nilai masih sering terjadi.

UNIVERSITAS
MA CHUNG

Model 3 - GLI



Gambar 4. 93 Grafik hasil pengujian model 3 input GLI




Gambar 4. 94 Diagram frekuensi kategori nilai JSD model 3 input GLI

6. Input NGRDI


Model ketiga yang dilatih dengan data NGRDI sebagian besar dapat menunjukkan perbedaan bentuk yang cukup signifikan dari kedua distribusi, terutama pada metrik LPIPS, SSIM dan FSIM, meskipun tetap banyak adanya *overlap* pada seluruh metrik.

UNIVERSITAS
MA CHUNG

Model 3 - NGRDI



Gambar 4. 95 Grafik hasil pengujian model 3 input NGRDI



Gambar 4. 96 Diagram frekuensi kategori nilai JSD model 3 input NGRDI

Untuk memperjelas analisis kemampuan setiap indeks dalam pemisahan data, disajikan rata-rata nilai JSD dan BD yang diperoleh pada eksperimen dengan model ketiga.

Tabel 4. 9 Rata-rata JSD dan BD per indeks vegetasi model 3

Model	Input	JSD	BD
Model 3	RGB	0.3218	0.2018
	VARI	0.3371	0.2272
	ExG	0.1900	0.0854
	ExR	0.2963	0.1879
	GLI	0.2631	0.1647
	NGRDI	0.3060	0.1964

Dari tabel 4.9, terlihat indeks VARI dengan nilai JSD 0.3371 dan BD 0.2272 konsisten unggul dibandingkan indeks lainnya dalam menunjukkan perbedaan bentuk distribusi serta pemisahan *overlapping* data.

4.5.4 Perbandingan Kinerja Metrik

Selain perbandingan nilai *Jensen-Shannon Divergence* (JSD) dan *Bhattacharyya Distance* (BD) pada setiap kombinasi model dan input, analisis performa juga dilengkapi dengan evaluasi berdasarkan rata-rata nilai JSD dan BD dari tiap kelompok input terhadap berbagai metrik evaluasi. Tujuannya adalah untuk memperoleh gambaran umum mengenai kestabilan dan konsistensi tiap jenis

input dalam menghasilkan perbedaan rekonstruksi citra antara pohon sehat dan pohon sakit, terlepas dari arsitektur model yang digunakan.

Tabel 4. 10 Perbandingan Rata-rata JSD dan BD tiap metrik

Input	Metrik	Rata-rata JSD	Rata-rata BD
RGB	MSE	0.1182	0.3529
	MAE	0.3672	0.3685
	LPIPS	0.2640	0.1392
	SSIM	0.2760	0.1562
	FSIM	0.2969	0.1551
VARI	MSE	0.0544	0.1842
	MAE	0.2442	0.2367
	LPIPS	0.2562	0.1358
	SSIM	0.5455	0.5150
	FSIM	0.5514	0.5133
ExG	MSE	0.0793	0.1271
	MAE	0.1496	0.1172
	LPIPS	0.2504	0.1282
	SSIM	0.2581	0.1380
	FSIM	0.2673	0.1739
ExR	MSE	0.0808	0.2154
	MAE	0.2231	0.2083
	LPIPS	0.2099	0.0794
	SSIM	0.3292	0.2018
	FSIM	0.3501	0.2173
GLI	MSE	0.0386	0.1942
	MAE	0.1969	0.1961
	LPIPS	0.2705	0.1335
	SSIM	0.4431	0.3606
	FSIM	0.4331	0.3513
NGRDI	MSE	0.0460	0.1329
	MAE	0.2206	0.2033
	LPIPS	0.2616	0.1634
	SSIM	0.4863	0.4030
	FSIM	0.4828	0.3955

Dari hasil yang didapatkan, serta didukung dengan tabel 4.10, ditemukan bahwa metrik SSIM (*Structural Similarity Index Measure*) dan FSIM (*Feature Similarity Index Measure*) cenderung menghasilkan nilai rata-rata yang lebih tinggi dibandingkan metrik lainnya. Metrik SSIM unggul pada input VARI di nilai BD

0.5150, GLI di nilai JSD 0.4431 dan BD 0.3606, dan NGRDI di nilai JSD 0.4863 dan BD 0.4030. Sedangkan FSIM unggul pada input VARI di nilai JSD 0.5514, ExG di nilai JSD 0.2673 dan BD 0.1739, serta ExR di nilai JSD 0.3501 dan BD 0.2173. Hal ini menunjukkan bahwa kedua metrik tersebut relatif lebih sensitif dalam mengukur perbedaan struktur dan fitur visual antara citra asli dan citra hasil rekonstruksi, sehingga lebih konsisten dalam mendeteksi anomali pada citra pohon sawit sakit. Namun, terdapat pengecualian khusus pada kelompok input RGB, di mana metrik MAE (*Mean Absolute Error*) menunjukkan nilai rata-rata yang lebih tinggi dibandingkan metrik lainnya. Temuan ini mengindikasikan bahwa untuk citra RGB, perbedaan piksel secara absolut lebih menonjol dan memberikan indikasi performa deteksi anomali yang lebih baik dibandingkan pendekatan lainnya. Hal ini diduga terjadi karena pada citra RGB, perbandingan juga dilakukan berdasarkan perbedaan warna, sehingga metrik MAE sangat baik dalam menunjukkan perbedaan antara citra sehat dan sakit karena perbedaan warna yang mencolok.

4.6 Pembahasan

Berdasarkan pembahasan hasil pada subbab 4.5, dapat dilihat bahwa indeks VARI secara konsisten menghasilkan nilai JSD dan BD yang tinggi dibandingkan indeks lainnya. Hal ini menunjukkan bahwa perbedaan distribusi antara citra sehat dan sakit paling tampak saat menggunakan input VARI. Setelah VARI, indeks NGRDI dan GLI juga menunjukkan nilai JSD dan BD yang relatif tinggi, meskipun tidak sebesar VARI. Temuan ini mengindikasikan bahwa ketiga indeks tersebut cenderung lebih sensitif dalam membedakan kondisi tanaman, terutama dalam konteks deteksi dini *Ganoderma* pada kelapa sawit.

Meskipun menghasilkan nilai perbedaan bentuk distribusi signifikan serta pemisahan data yang tampak optimal, ketika ditinjau lebih lanjut secara visual dan logis, pola distribusi yang terbentuk menunjukkan kecenderungan yang tidak sesuai dengan ekspektasi awal. Ditemukan perilaku berkebalikan pada hasil penghitungan metrik-metrik terhadap citra hasil rekonstruksi. Harapan awal yang ingin dicapai dari penelitian ini ialah terdapat perbedaan nilai metrik antara citra hasil rekonstruksi sehat dan sakit, di mana seharusnya rekonstruksi citra sakit menunjukkan kualitas yang lebih rendah. Namun, hasil yang didapatkan pada

penelitian ini justru memperlihatkan bahwa tingkat kemiripan rekonstruksi citra sakit cenderung lebih tinggi dibandingkan citra sehat.

Kondisi ini diduga terjadi karena perbedaan kompleksitas struktur antara citra awal sehat dan sakit. Citra sehat umumnya memiliki struktur dan bentuk visual yang lebih rumit karena bentuk daun tanaman masih utuh dan terlihat jelas. Sedangkan pada citra sakit, struktur daun tanaman sudah tidak serumit citra sehat karena daun-daun tersebut telah mengering dan rontok. Hal ini mengakibatkan struktur yang lebih sederhana tersebut, meskipun belum pernah dikenali oleh model, cenderung tetap dapat direkonstruksi dengan baik.



BAB V

Simpulan dan Saran

5.1 Simpulan

Berdasarkan hasil yang diperoleh pada penelitian ini, efektivitas deteksi dini *Ganoderma* pada kelapa sawit dapat ditingkatkan dengan memanfaatkan citra yang telah dikonversi ke dalam bentuk indeks vegetasi berbasis RGB. Dibandingkan dengan menggunakan citra RGB secara langsung, penggunaan beberapa indeks vegetasi mampu memberikan representasi yang lebih sensitif terhadap kondisi kesehatan tanaman. Pernyataan ini didukung dengan nilai metrik yang didapat pada penelitian ini di mana beberapa indeks vegetasi dapat melampaui RGB dalam membedakan citra sawit sehat dan sakit.

Lebih lanjut, untuk menentukan indeks vegetasi yang paling sesuai untuk deteksi dini *Ganoderma*, penelitian ini melakukan perbandingan terhadap lima jenis indeks vegetasi, yaitu VARI, ExG, ExR, GLI, dan NGRDI. Berdasarkan hasil pengujian menggunakan tiga arsitektur model autoencoder, ditemukan bahwa indeks VARI menunjukkan performa yang paling konsisten dan unggul dibandingkan indeks lainnya. Indeks ini mampu menghasilkan nilai evaluasi terbaik berdasarkan nilai perbedaan bentuk distribusi dan tingkat *overlapping* data. Input VARI menghasilkan nilai JSD tertinggi pada model pertama dengan nilai 0.3323, nilai BD tertinggi pada model kedua dengan nilai 0.3873, serta nilai JSD dan BD tertinggi pada model ketiga dengan nilai 0.3371 dan 0.2272. Oleh karena itu, indeks VARI direkomendasikan sebagai input optimal dalam sistem deteksi dini penyakit *Ganoderma boninense* pada kelapa sawit. Beserta dengan itu pula, terdapat indeks GLI dan NGRDI yang juga dapat dipertimbangkan untuk digunakan karena memiliki nilai JSD dan BD yang juga cenderung tinggi. Input GLI menghasilkan BD tertinggi di model 1 dengan nilai 0.3575, dan NGRDI menghasilkan JSD 0.3258 di model 2.

Untuk melengkapi evaluasi, penilaian kemampuan rekonstruksi dinilai dengan metrik-metrik MSE, MAE, LPIPS, SSIM dan FSIM. Pada penelitian ini ditemukan bahwa metrik SSIM dan FSIM cenderung unggul dalam memperlihatkan perbedaan bentuk distribusi antara sawit sehat dan sakit yang dilatih dengan citra hasil ekstraksi indeks vegetasi. Kedua metrik ini dapat

menunjukkan secara jelas perbedaan signifikan dari distribusi serta pemisahan data yang cukup baik. Namun perlu dijadikan catatan bahwa meski data tampak berbeda, terdapat keterbalikan logika antara nilai kemiripan hasil rekonstruksi antara citra sawit sehat dan sakit.

5.1 Saran

Berdasarkan hasil penelitian yang telah dilakukan serta temuan-temuan yang diperoleh selama proses analisis dan evaluasi, terdapat beberapa saran yang dapat diberikan untuk mengembangkan penelitian lebih lanjut.

1. Perbaiki arsitektur model supaya dapat lebih peka dalam mengekstraksi fitur citra sawit sehat, serta mendeteksi anomali pada citra sawit sakit dengan lebih baik.
2. Perluasan penggunaan metrik penilaian yang mampu menunjukkan perbedaan citra asli dengan citra hasil rekonstruksi dari segi struktur dan warna
3. Peningkatan kualitas dataset dengan meningkatkan resolusi citra dan pemilihan citra sehat yang cermat supaya model mampu mempelajari karakteristik citra sehat secara lebih mendalam.

UNIVERSITAS
MA CHUNG

Daftar Pustaka

- Adinata, M. (2025). *Analisis Kinerja Convolutional Autoencoder (CAE) untuk Deteksi Pohon Kelapa Sawit Terinfeksi Ganoderma*. Malang: Universitas Ma Chung.
- Adkisson, M., Kimmel, J. C., Gupta, M., & Abdelsalam, M. (2021). Autoencoder-based Anomaly Detection in Smart Farming Ecosystem. *arXiv preprint arXiv:2111.00099*. doi:<https://doi.org/10.48550/arXiv.2111.00099>
- Anuar, I., Noor, N. M., Seman, I. A., & Hamzah. (2020). Analysis of Multispectral Imagery from Unmanned Aerial Vehicle (UAV) using Object-Based Image Analysis for Detection of Ganoderma Disease in Oil Palm. *Journal of Oil Palm Research*, 497-508.
- Armita, D., Putra, A. N., Sudarto, Nita, I., Kusumawati, H., Wahyudianto, R., . . . Putri, R. L. (2022). Penerapan Citra Sentinel 2-A dalam Pendugaan Kalium pada Kentang. *Jurnal Tanah dan Sumberdaya Lahan*, 141-146.
- Avneon, Y. (2023, Maret 23). *Bhattacharyya distance: From statistics to application in data science*. Retrieved from Medium: <https://medium.com/@yoavyeledteva/bhattacharyya-distance-from-statistics-to-application-in-data-science-8eb5ccdbba62>
- Bedi, P., & Gole, P. (2021). Plant Disease Detection using Hybrid Model Based On Convolutional Autoencoder and Convolutional Neural Network. *Artificial Intelligent in Agriculture*, 90-101.
- Benedict, J. J., & Heilmayr, R. (2024, Oktober 8). *Trase: Indonesian palm oil exports and deforestation*. Retrieved from Stockholm Environment Institute: <https://www.sei.org/features/indonesian-palm-oil-exports-and-deforestation/>
- Bergmann, D., & Stryker, C. (2023, November 23). *What is an autoencoder?* Retrieved from IBM: <https://www.ibm.com/id-id/think/topics/autoencoder>
- Corteva. (2020, Juli 21). *Penyakit Pada Tanaman Kelapa Sawit dan Cara Mencegahnya*. Retrieved from Corteva Agriscience: <https://www.corteva.id/berita/Penyakit-Pada-Tanaman-Kelapa-Sawit-dan-Cara-Mencegahnya.html>
- Dhinakaran, A. (2023, Maret 2). *How to Understand and Use the Jensen-Shannon Divergence*. Retrieved from Medium: <https://medium.com/data-science/how-to-understand-and-use-jensen-shannon-divergence-b10e11b03fd6>
- Dohmen, M., Klemens, M. A., Baltruschat, I. M., Truong, T., & Lenga, M. (2025). Similarity and quality metrics for MR image-to-image translation. *Sci Rep*, 1-18.
- Dwyer, B., & Gallagher, J. (2023, Maret 16). *Getting Started with Roboflow*. Retrieved from Roboflow: <https://blog.roboflow.com/getting-started-with-roboflow/>
- Frackiewicz, M., Machalicha, L., & Palus, H. (2024). New Combined Metric for Full-Reference Image Quality Assessment. *Symmetry*, 1-21.

- Gama Statistika. (2024, Desember 23). *Peran Penting QGIS untuk Analisis Geografis dalam Skripsi*. Retrieved from Gama Statistika: https://gamastatistika.com/2024/12/23/peran-penting-qgis-untuk-analisis-geografis-dalam-skripsi/?utm_source=chatgpt.com
- Ghazanfari, S., Garg, S., Krishnamurthy, P., Khorrami, F., & Araujo, A. (2023). R-LPIPS: An Adversarially Robust Perceptual Similarity Metric. *arXiv: 2307.15157v2*.
- Ginting, E. N., & Wiratmoko, D. (2021). Potensi dan Tantangan Penerapan Precision Farming dalam Upaya Membangun Perkebunan Kelapa Sawit yang Berkelanjutan. *Warta PPKS*, 55-56.
- Harris, C. R., Millman, K. J., Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., . . . Oliphant, T. E. (2020). Array Programming with NumPy. *Nature*, 357-362.
- Hunter, J., Dale, D., Firing, E., & Droettboom, M. (2023). *Matplotlib: Visualization with Python*. Retrieved from matplotlib: <https://matplotlib.org/>
- Karunarathna, S. C., Patabendige, N. M., Lu, W., Asad, S., & Hapuarachchi, K. K. (2024). An In-Depth Study of Phytopathogenic Ganoderma: Pathogenicity, Advanced Detection Techniques, Control Strategies, and Sustainable Management. *Journal of Fungi*, 414-492.
- Kementerian Keuangan Republik Indonesia. (2024, November 21). *Industri Kelapa Sawit Berperan Strategis bagi Perekonomian Indonesia*. Retrieved from Kementerian Keuangan Republik Indonesia: <https://www.kemenkeu.go.id/informasi-publik/publikasi/berita-utama/Peran-Strategis-Industri-Kelapa-Sawit>
- Mahmud, Y., Romantis, C., & Zam, S. I. (2020). Efektifitas Trichoderma virens dalam Mengendalikan Ganoderma boninense di Pre Nursery Kelapa Sawit pada Medium Gambut. *Jurnal Agroteknologi*, 11-16.
- Majalah Hortus. (2024, Februari 27). *Tantangan Industri Kelapa Sawit di Tahun 2024*. Retrieved from Gapki: <https://news.majalahhortus.com/tantangan-industri-kelapa-sawit-di-tahun-2024/>
- Meyer, A. (2017). *Saliency Detection Convolutional Autoencoder*. Retrieved from GitHub: https://github.com/arthurmeyer/Saliency_Detection_Convolutional_Autoencoder
- Mujkic, E., Philipsen, M. P., Moeslund, T. B., Christiansen, M. P., & Ravn, O. (2022). Anomaly Detection for Agricultural Vehicles Using Autoencoders. *sensors*, 1-15.
- Mukherjee, S. (2023, Mei 4). *Autoencoders with Convolutions*. Retrieved from Scaler Topics: <https://www.scaler.com/topics/deep-learning/convolutional-autoencoder/>
- Nurliana, Ginting, M. S., Guntoro, & Fenni, R. A. (2022). Laju Infeksi Penyakit Busuk Pangkal Batang (BPB) pada Tanaman Kelapa Sawit di Divisi I Kebun Bangun Bandar PT Socfindo. *Jurnal Budidaya Perkebunan Kelapa Sawit dan Karet*, 99-107.

- Nuwara, Y., Wong, W. K., & Juwono, F. (2022). Modern Computer Vision for Oil Palm Tree Health Surveillance using YOLOv5. *International Conference on Green Energy, Computing and Sustainable Technology (GECOST)*, 404-409.
- Pandey, A. K. (2024, Maret 9). *Structural Similarity Index (SSIM)*. Retrieved from Medium: <https://medium.com/@akp83540/structural-similarity-index-ssim-c5862bb2b520>
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., . . . Chintala, S. (2019). PyTorch: An Imperative Style, High-Performance Deep Learning Library. *Advances in Neural Information Processing Systems* (pp. 1-12). Vancouver: NIPS Papers.
- Pawar, S. (2025, Februari 27). *Understanding JS Divergence for Feature Selection: A Hands-On Guide with Evidently*. Retrieved from Medium: <https://medium.com/%40shridharpawar77/understanding-js-divergence-for-feature-selection-a-hands-on-guide-with-evidently-d10570fbc628>
- Prasetya, F. V., & Insan, A. F. (2021). Sebaran Land Surface Temperature Dan Indeks Vegetasi Di Wilayah Kota Semarang Pada Bulan Oktober 2019. *Buletin Poltanesa*, 45-52.
- Prayogo, A. K. (2023). Studi Perbandingan Model Konvolusi ConvBiLSTM, ConvLSTM, dan Non-Konvolusi LSTM untuk Prediksi Perkembangan Penyakit Ganoderma pada Citra UAV Perkebunan Kelapa Sawit PTPN. *Tugas Akhir Universitas Ma Chung*.
- Radočaj, D., Šiljeg, A., Marinović, R., & Jurišić, M. (2023). State of Major Vegetation Indices in Precision Agriculture Studies Indexed in Web of Science: A Review. *Agriculture*, 1-16.
- Rahmana, B. A., Hayata, & Hartawan, R. (2024). Intensitas Serangan Jamur Ganoderma sp pada Perkebunan Kelapa Sawit Lahan Mineral dan Lahan Pasang Surut. *Jurnal Media Pertanian*, 148-154.
- Rahmawati, S. E., & Hermawan, D. (2023). Analisis Komparatif Penggunaan Indeks Vegetasi Daerah Normalized Difference Vegetation Index (NDVI) dan Soil Adjusted Vegetation Index (SAVI) dalam Mendeteksi Tingkat Vegetasi di Areal Bekas Tambang. *Prosiding Temu Profesi Tahunan PERHAPI* (pp. 709-720). Samarinda: PERHAPI.
- Redaksi SawitKita. (2024, April 19). *Mendeteksi Ganoderma dengan Alat Deteksi Portable*. Retrieved from sawitkita: <https://sawitkita.id/mendeteksi-ganoderma-dengan-alat-deteksi-portable>
- Robeson, S. M., & Willmott, C. J. (2023). Decomposition of the mean absolute error (MAE) into systematic and unsystematic components. *PLoS ONE*, 1-8.
- Sakti, A. N., Khurizil, M. M., Aprilia, D. N., Sudarti, & Trapsilo. (2023). Efektifitas Drone sebagai Media Penginderaan Jauh untuk Pemantauan Kesehatan Tanaman. *Jurnal Technopreneur (JTech)*, 50-55.
- SawitNotif. (2018, Februari 21). *Busuk Pangkal Batang pada Tanaman Kelapa Sawit*. Retrieved from Plantation Key Technology: <https://pkt-group.com/sawitnotif/busuk-pangkal-batang-pada-tanaman-kelapa-sawit/>

- Senewe, R. E., Pesireron, M., & Sahetapy, B. (2023). Penyakit Busuk Pangkal Batang (BPB) Tanaman Kelapa Sawit Oleh Patogen Ganoderma SPP. *Journal of Top Agriculture (Top Journal)*, 65-73.
- Sergieieva, K. (2025, Maret 28). *Vegetation Indices To Drive Digital Agri Solutions*. Retrieved from Eos Data Analytics: <https://eos.com/blog/vegetation-indices/>
- Smart agribusiness and food. (2024, September 18). *Ganoderma 101: Musuh kelapa sawit yang perlu Anda kenali*. Retrieved from Smart agribusiness and food: <https://www.smart-tbk.com/ganoderma-101-musuh-kelapa-sawit-yang-perlu-anda-kenali>
- Soesanto, O., Idris, M., & Hastomo, H. D. (2022). Segmentasi Vegetasi Lahan Basah Berbasis Modified-Camera Drone. *Prosiding Seminar Nasional Lingkungan Lahan Basah*, 259-266.
- Suharyanto, Eris, D. D., Prakoso, H. T., Saragih, A. H., & Darmono, T. W. (2016). Perangkat Serologi untuk Deteksi Dini Infeksi Ganoderma sp. pada Kelapa Sawit. *Menara Perkebunan*, 8-16.
- Supriyono, J. (2023, November 13). *Sejarah Kelapa Sawit Indonesia*. Retrieved from Gapki: <https://gapki.id/news/2017/11/28/video-sejarah-kelapa-sawit-indonesia/>
- Team Algoritma. (2023, Maret 30). *Autoencoder: Mengungkap Pola Tersembunyi dalam Data yang Kompleks*. Retrieved from algoritma: <https://blog.algoritma/autoencoder/#2-autoencoder-convolutional>
- Vianna, M. S., Matias, F. I., Galli, G., Martins, E. S., Oliveira, M., & Pinheiro, J. B. (2025). Using Red-green-blue Vegetation Indices to Evaluate Complex Agronomical Traits in Soybean Breeding. *Agronomy Journal*, 1-12.
- Wahyuni, M., Sabrina, T., Mukhlis, & Santoso, H. (2022). Aplikasi Support Vector Machine pada Deteksi Penyakit Busuk Pangkal Batang Ganoderma Tanaman Kelapa Sawit. *Prosiding Seminar Nasional Instiper*, 105-115.
- Wicaksono, G. (2023). Pemanfaatan QGIS dalam Pengembangan Kota Digital Berbasis Analisis Spasial: Studi Kasus Surakarta sebagai Smart City. *Journal of Digital Architecture*, 21-26.
- Wicaksono, W., Prilianti, K. R., Setiawan, H., & Mimboro, P. (2022). Metode Deteksi Cepat Serangan Ganoderma pada Perkebunan Kelapa Sawit dengan Penginderaan Jauh. *Journal of Embedded System Security and Intelligent System*, 135-142.
- Wilianto, K. (2021, Oktober 8). *Elemen Penting dalam Deep Learning for Computer Vision yang Harus Diketahui Sebelum Membuat Model Pertamamu!* Retrieved from Medium: <https://medium.com/data-folks-indonesia/elemen-penting-dalam-deep-learning-for-computer-vision-yang-harus-diketahui-sebelum-membuat-model-d74b1befb1d0>
- Wilyani, F., Arif, Q. N., & Aslimar, F. (2024). Pengenalan Dasar Pemrograman dengan Google Colaboratory. *Jurnal Pengabdian Pada Masyarakat Indonesia (JPPMI)*, 8-14. doi:<https://doi.org/10.55606/jppmi.v3i1.1087>