

**DETEKSI ANOMALI PADA SISTEM SMART AEROPONIK
MENGUNAKAN ALGORITMA *ISOLATION FOREST*:
STUDI KASUS SENSOR IOT**

SKRIPSI

Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Teknik pada Program
Studi Teknik Elektro Fakultas Teknik Universitas Islam Nusantara Bandung

Oleh:

AHMAD KURNIA

41037002211024



PROGRAM STUDI TEKNIK ELEKTRO

FAKULTAS TEKNIK

UNIVERSITAS ISLAM NUSANTARA

BANDUNG

2025

LEMBAR KEASLIAN SKRIPSI

Yang bertanda tangan di bawah ini :

Nama : Ahmad Kurnia

NIM : 41037002162002

Program studi : Teknik Elektro

menyatakan bahwa skripsi
yang berjudul:

DETEKSI ANOMALI PADA SISTEM SMART AEROPONIK
MENGUNAKAN ALGORITMA *ISOLATION FOREST*:
STUDI KASUS SENSOR IOT dengan sebenar-benarnya dari
penelitian, pemikiran, dan pemaparan hasil saya sendiri, untuk
melengkapi sebagai pernyataan menjadi Sarjana (S1) pada jurusan
Teknik Elektro Fakultas Teknik Universitas Islam Nusantara
Bandung, sejauh yang saya ketahui bukan merupakan tiruan atau
duplikasi dari buku Skripsi yang sudah dipublikasikan dan atau
pernah dipakai untuk mendapatkan jenjang Sarjana (S1) di
lingkungan Teknik Elektro Fakultas Teknik Universitas Islam
Nusantara Bandung maupun perguruan-perguruan tinggi atau
instansi manapun kecuali bagian yang sumber informasi
dicantumkan sebagaimana mestinya.

Bandung, 21 April 2025

Yang membuat pernyataan,

AHMAD KURNIA

NIM. 41037002211024

LEMBAR PENGESAHAN

**DETEKSI ANOMALI PADA SISTEM SMART AEROPONIK
MENGUNAKAN ALGORITMA *ISOLATION FOREST*: STUDI
KASUS SENSOR IOT**

Disusun dan diajukan oleh:

AHMAD KURNIA

41037002211024

Disetujui dan disahkan pada sidang skripsi

pada tanggal:

Bandung, 21 April 2025

Pembimbing I

Pembimbing II

Dr. Iksal Rachman, M.T.

Ir. Joko Haryatno, M.T.

Mengetahui:

Dekan Fakultas Teknik

Ketua Kaprodi Teknik Elektro

Dr. Ricky Yoseptry, M.M.Pd.

Muhammad Zimamul Adli, M.Si.

LEMBAR PENGESAHAN

REVISI SKRIPSI

**DETEKSI ANOMALI PADA SISTEM SMART AEROPONIK
MENGUNAKAN ALGORITMA *ISOLATION FOREST*: STUDI
KASUS SENSOR IOT**

Telah direvisi oleh:

AHMAD KURNIA

41037002211024

Bandung, 19 Mei 2025

Mengesahkan

Penguji I

Penguji II

Ganis Sanhaji, S.Si., M.Sc.

Osphanie Mentari, S.T., M.T., M.Eng.

Ketua sidang

Muhammad Zimamul Adli, M.Si.

BIODATA PENULIS



Nama	: Ahmad Kurnia
Tempat, tanggal lahir	: Bandung, 28 oktober 2001
Telepon	: 0895603663750
Email	: kurniaahmad950@gmail.com
Riwayat pendidikan	: SD Negeri Cisaranten Kidul SMP Negeri 51 Bandung SMK Negeri 6 Bandung

KATA PENGANTAR

Puji syukur penulis panjatkan kehadirat Allah SWT, Tuhan Yang Maha Kuasa, atas limpahan rahmat, kasih sayang, serta hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul "DETEKSI ANOMALI PADA SISTEM SMART AEROPONIK MENGGUNAKAN ALGORITMA *ISOLATION FOREST*: STUDI KASUS SENSOR IOT". Skripsi ini merupakan salah satu syarat untuk menyelesaikan pendidikan Strata Satu (S1) di Universitas Islam Nusantara, Fakultas Teknik, Program Studi Teknik Elektro.

1. Dalam perjalanan panjang penyusunan skripsi ini, penulis tidak akan sampai pada titik ini tanpa dukungan, doa, dan bantuan dari berbagai pihak. Dengan hati yang penuh rasa syukur dan hormat, penulis menyampaikan rasa terima kasih yang mendalam kepada:
2. Allah SWT, yang senantiasa memberikan kekuatan, kesehatan, dan petunjuk di setiap langkah penulis. Segala sesuatu adalah karena kehendak-Nya, dan penulis memohon semoga karya ini menjadi bermanfaat.
3. Untuk ibu saya, Ibu yayah, serta kakak-kakak saya tercinta, terima kasih atas segala doa, dukungan, dan kasih sayang yang tak pernah putus. Ibu dengan ketulusan dan pengorbananmu telah menjadi cahaya penuntun dalam setiap langkah saya. Kepada kakak-kakak saya, terima kasih atas setiap nasihat, dorongan, dan rasa peduli yang selalu menguatkan saya untuk berdiri tegak. Kehadiran kalian membuat saya belajar arti tanggung jawab, kebersamaan, dan perjuangan, hingga akhirnya saya dapat sampai pada tahap ini. Tak lupa, ucapan terima kasih kepada seluruh keluarga besar penulis yang telah menjadi pilar kekuatan selama ini.
4. Bapak Dr. Iksal Rachman, M.T. dan bapak Ir. Joko Haryatno, M.T. selaku dosen pembimbing skripsi, atas bimbingan, arahan, dan kesabaran dalam membantu penulis menyelesaikan skripsi ini.
5. Bapak Ganis Sanhaji, S.Si., M.Sc., wali dosen Studi Teknik Elektro terimakasih atas bimbingan, arahan selama menjadi wali dosen

6. Dr. Ricky Yoseptry, S.T., M.M.Pd., selaku Dekan Fakultas Teknik, yang telah memberikan dukungan dan motivasi kepada penulis selama masa perkuliahan.
7. Seluruh dosen Fakultas Teknik, yang telah dengan tulus memberikan ilmu dan pengalaman berharga yang menjadi bekal bagi penulis.
8. Seluruh staf Tata Usaha Fakultas Teknik, yang telah membantu penulis dalam menyelesaikan berbagai urusan administrasi kemahasiswaan dengan penuh kesabaran.
9. Prof. Dr. Endang Komara, M.Si., selaku Rektor Universitas Islam Nusantara, yang telah memberikan kesempatan kepada penulis untuk menimba ilmu di universitas tercinta ini.
10. Kepada seseorang yang tidak dapat penulis sebutkan namanya, terima kasih karena pernah hadir mendampingi selama masa perkuliahan. Kehadiranmu sempat memberi warna, semangat, bahkan pelajaran berharga dalam perjalanan ini. Meski akhirnya jalan yang ditempuh berbeda, perginya dirimu justru menghadirkan motivasi baru untuk terus maju, belajar arti pengalaman, pendewasaan, kesabaran, dan menerima kehilangan sebagai bagian dari proses hidup. Terima kasih telah menjadi bagian yang menyenangkan sekaligus menyakitkan dari perjalanan ini, sebab pada akhirnya setiap orang ada masanya, dan setiap masa ada orangnya.
11. Seluruh teman-teman Teknik Elektro angkatan 2021, yang telah memberikan warna, dukungan, dan kebersamaan selama masa perkuliahan.
12. Semua pihak yang tidak dapat penulis sebutkan satu per satu, yang telah membantu, mendukung, dan mendoakan penulis selama ini.

Akhirnya, penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan. Oleh karena itu, saran dan kritik yang membangun sangat di harapkan demi perbaikan di masa mendatang. Semoga karya ini dapat memberikan manfaat bagi siapa saja yang membacanya.

ABSTRAK

Nama : Ahmad Kumia

Program studi : Teknik Elektro

Judul : DETEKSI ANOMALI PADA SISTEM SMART AEROPONIK MENGGUNAKAN ALGORITMA *ISOLATION FOREST*: STUDI KASUS SENSOR IOT

Pertanian urban dengan sistem aeroponik berbasis Internet of Things (IoT) membutuhkan pemantauan kondisi lingkungan yang akurat untuk mendukung pertumbuhan tanaman yang optimal. Namun, data sensor yang dikumpulkan sering mengandung anomali akibat kesalahan pengukuran atau gangguan sistem, yang dapat mengganggu pengambilan keputusan. Penelitian ini mengembangkan sistem deteksi anomali pada data sensor IoT dalam sistem smart aeroponik menggunakan algoritma Isolation Forest. Metode ini mampu mengisolasi data yang menyimpang secara efisien tanpa memerlukan data berlabel. Data yang diproses meliputi suhu, kelembaban, pH, dan konsentrasi nutrisi tanaman. Proses dimulai dari pengumpulan data historis sensor, pra-pemrosesan dengan pembersihan dan normalisasi, hingga pelatihan model Isolation Forest untuk mendeteksi anomali.

Hasil evaluasi menunjukkan model memiliki precision sebesar 62% dalam mengidentifikasi data normal, namun recall untuk anomali masih rendah pada 15%, menandakan perlunya peningkatan sensitivitas model terhadap anomali yang jarang muncul. Sistem prototipe berhasil diintegrasikan ke platform web berbasis FastAPI dan Streamlit, memungkinkan pemantauan real-time dengan visualisasi interaktif dan pembaruan data setiap tiga detik. Penelitian ini memberikan kontribusi praktis bagi pertanian urban dengan menyediakan sistem otomatis yang meningkatkan keandalan monitoring lingkungan aeroponik serta potensi pengembangan model deteksi anomali yang lebih akurat.

Kata Kunci: deteksi anomali, smart aeroponik, Internet of Things, Isolation Forest, monitoring real-time, machine learning.

ABSTRACT

Name : Ahmad Kurnia

Department : Electrical Engineering

Title : *Anomaly Detection in Smart Aeroponic Systems Using the Isolation Forest Algorithm: A Case Study of IoT Sensors*

Urban farming with an aeroponic system based on the Internet of Things (IoT) requires accurate environmental condition monitoring to support optimal plant growth. However, the sensor data collected often contains anomalies due to measurement errors or system disturbances, which can disrupt decision-making. This study develops an anomaly detection system on IoT sensor data within a smart aeroponic system using the Isolation Forest algorithm. This method efficiently isolates deviating data without the need for labeled data. The processed data includes temperature, humidity, pH, and plant nutrient concentration. The process begins with the collection of historical sensor data, followed by preprocessing involving cleaning and normalization, and then training the Isolation Forest model to detect anomalies. Evaluation results show that the model achieves a precision of 62% in identifying normal data, but the recall for anomalies remains low at 15%, indicating a need to improve the model's sensitivity to rare anomalies. The prototype system was successfully integrated into a web platform based on FastAPI and Streamlit, enabling real-time monitoring with interactive visualization and data updates every three seconds. This study provides practical contributions to urban farming by delivering an automated system that enhances the reliability of aeroponic environmental monitoring and the potential development of more accurate anomaly detection models.

Keywords: *anomaly detection, smart aeroponics, Internet of Things, Isolation Forest, real-time monitoring, machine learning.*

DAFTAR ISI

LEMBAR KEASLIAN SKRIPSI	i
LEMBAR PENGESAHAN	ii
LEMBAR PENGESAHAN	iii
BIODATA PENULIS.....	iv
KATA PENGANTAR.....	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI.....	ix
DAFTAR TABEL	xii
DAFTAR GAMBAR.....	xiii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Masalah.....	3
1.4 Tujuan penelitian.....	4
1.5 Manfaat penelitian.....	4
1.5.1. Manfaat Teoritis	4
1.5.2. Manfaat Praktis	5
1.6 Jadwal Penelitian.....	6
BAB II LANDASAN TEORI	7
2.1 Penelitian terdahulu.....	7
2.2 Sistem Smart Aeroponik berbasis Internet of Things (IoT)	12
2.2.1. Internet of Things (IoT)	12
2.2.2. Sistem Smart Aeroponik berbasis IoT.....	13
2.3 Anomali.....	16
2.3.1. Anomali dalam Pengumpulan Data	16
2.4 Parameter yang Diamati dalam Mendeteksi Anomali.....	16
2.4.1. Suhu	16
2.4.2. Kelembaban.....	17
2.4.3. pH.....	17

2.4.4.	Konsentrasi Nutrisi (ppm).....	17
2.5	Machine Learning	18
2.5.1.	Unsupervised Learning untuk Deteksi Anomali	18
2.6	Metode Isolation Forest untuk Mendeteksi Anomali	19
2.6.1.	Pengertian Isolation Forest.....	19
2.6.2.	Mekanisme Kerja Isolation Forest	19
2.6.3.	Keunggulan Isolation Forest	20
2.6.4.	Aplikasi Isolation Forest dalam Deteksi Anomali	20
2.6.5.	Tantangan dalam Penerapan Isolation Forest.....	21
BAB III	ANALISIS DAN PERANCANGAN SISTEM	22
3.1	Desain penelitian.....	22
3.2	Kerangka berpikir.....	22
3.3	Jenis penelitian	25
3.4	Pendekatan penelitian.....	25
3.5	Variabel penelitian.....	27
3.5.1.	Variabel independen (variabel bebas)	27
3.5.2.	Variabel dependen (variabel terikat)	27
3.6	Alur penelitian.....	28
3.7	Perancangan sistem	30
3.7.1.	Deskripsi sistem	30
3.7.2.	Sensor.....	30
3.7.3.	Aktuator.....	33
3.7.4.	Kontroler	34
3.8	Metode deteksi anomali	35
3.8.1.	Implementasi isolation forest	35
3.8.1.1.	Pengumpulan data	35
3.8.1.2.	Pra-pemrosesan data.....	36
3.8.1.2.1.	Data cleansing	36
a)	Missing value	36
b)	Menghapus duplikasi	36
c)	Transformasi data.....	37
d)	Menyimpan data yang telah diproses	37

3.8.1.2.2.	Membuat model	38
a)	Menetapkan Nilai Kontaminasi	38
b)	Menghitung Skor Anomali.....	39
3.8.1.2.3.	Evaluasi model	40
a)	Precision.....	40
b)	Recall.....	41
c)	F1-score.....	41
3.9	Analisis dan interpretasi hasil.....	42
BAB IV	HASIL DAN PEMBAHASAN.....	44
4.1	Pembuatan Model Deteksi Anomali Menggunakan Isolation Forest....	44
4.1.1.	Data Sensor yang Digunakan	44
4.1.2.	Proses Preprocessing Data	45
4.1.2.1.	Cleaning	46
4.1.2.2.	Normalisasi	47
4.1.2.3.	Training dan Parameterisasi Model Isolation Forest.....	48
4.1.2.4.	Evaluasi Kinerja Model.....	51
a)	Classification Report.....	52
b)	Confusion Matrix	53
c)	Dunn Index.....	56
4.2	Identifikasi dan Klasifikasi Anomali Berdasarkan Hasil Deteksi	57
4.2.1.	Hasil Deteksi Anomali	57
4.2.2.	Analisis Hasil Deteksi Anomali	58
4.3	Integrasi Model Deteksi Anomali ke dalam Sistem Web Monitoring ..	62
4.3.1.	Arsitektur Sistem.....	62
BAB V	KESIMPULAN DAN SARAN.....	66
5.1	Kesimpulan	66
5.2	Saran.....	67
	DAFTAR PUSTAKA	68
	LAMPIRAN.....	74

DAFTAR TABEL

Tabel 1. 1 Jadwal Penelitian	6
Tabel 2. 1 Penelitian terdahulu	7
Tabel 3. 1 Form Uji.....	43
Tabel 4. 1 Sampel Data Yang Digunakan	44
Tabel 4. 2 Hasil Hapus Kolom Pada Data	47
Tabel 4. 3 Hasil Uji.....	58
Tabel 4. 4 Tabel Korelasi Hasil Pengujian.....	59

DAFTAR GAMBAR

Gambar 2. 1 Mekanisme Iot	12
Gambar 2. 2 Sistem Aeroponik.....	14
Gambar 2. 3 Ilustrasi Model Isolation Forest	19
Gambar 3. 1 Kerangka Berpikir	24
Gambar 3. 2 Alur Penelitian	30
Gambar 3. 3 Sensor PH	31
Gambar 3. 4 Sensor TDS	31
Gambar 3. 5 Sensor DS18B20.....	32
Gambar 3. 6 Sensor SHT2O	32
Gambar 3. 7 Pompa	33
Gambar 3. 8 Nozzle	34
Gambar 3. 9 Mikrokontroler.....	34
Gambar 4. 1 Upload Data Dan Print Data	45
Gambar 4. 2 Proses Hapus Kolom.....	46
Gambar 4. 3 Hasil Normalisasi Data	48
Gambar 4. 4 Proses Epoch.....	50
Gambar 4. 5 Hasil Train Model	50
Gambar 4. 6 Hasil Evaluasi Model.....	52
Gambar 4. 7 Confusion Matrix.....	53
Gambar 4. 8 Matrix Evaluasi.....	54
Gambar 4. 9 Matrix Dunn Index	56
Gambar 4. 10 Heatmap Matrix	59
Gambar 4. 11 Hasil Deteksi Korelasi Data Uji.....	60
Gambar 4. 12 Alur Deployment	63
Gambar 4. 13 Interface User.....	63

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pertanian urban adalah salah satu bentuk pemenuhan kebutuhan pangan yang penting dan kini mulai marak dilakukan oleh orang-orang di perkotaan. Pertanian di perkotaan dapat diimplementasikan di area-area yang terbatas seperti balkon, atap, lahan kosong, dan dinding. Salah satu sistem yang digunakan untuk pertanian urban adalah sistem aeroponik.

Sistem aeroponik merupakan salah satu sistem pertanian modern tanpa menggunakan media tanah, dimana nutrisi tanaman disemprotkan dengan menggunakan alat penyemprot khusus. Hasil pertanian yang optimal sangat bergantung pada pemantauan kondisi lingkungan dan kesehatan tanaman itu sendiri. Oleh karena itu, penting untuk memperoleh data yang akurat dari berbagai sensor agar dapat mencegah kerugian dari kondisi yang tidak sesuai (Prawiranegara, 2023; Wulandari & Sumiar, 2021; Perteka et al., 2020).

Untuk memperoleh data-data tersebut secara akurat dan *real-time*, beberapa sensor, seperti sensor suhu air, kelembaban, nutrisi konsentrat (ppm), dan pH, digunakan secara terintegrasi dengan teknologi *Internet of Things* (IoT) (Perteka et al., 2020; Husaini et al., 2021). Namun, terkadang masalah muncul dalam mendeteksi anomali, dimana hal tersebut mengindikasikan adanya masalah di dalam sistem, seperti kegagalan sistem sensor atau adanya perubahan mendadak di lingkungan media tanam. Sistem sensor yang dapat mendeteksi anomali secara efektif dapat membantu dalam pengambilan keputusan yang tepat agar tanaman sehat dan hasil panen melimpah (Wulandari & Sumiar, 2021; Husaini et al., 2021).

Metode *isolation forest* merupakan salah satu teknik yang efektif untuk mendeteksi anomali. Metode ini beroperasi dengan cara mengisolasi

data yang berbeda dari data yang lainnya, sehingga dapat mengidentifikasi pola yang tidak biasa (Nugroho & Abdullah, 2022). Dalam konteks sistem smart aeroponik, penerapan metode ini dapat mempermudah untuk mendeteksi kesalahan pengukuran dari sensor atau perubahan kondisi yang tidak diharapkan, sehingga mempermudah untuk mengambil tindakan pencegahan yang lebih cepat tanggap (Nugroho & Abdullah, 2022; Perteka et al., 2020).

Dalam penelitian yang dilakukan sebelumnya, sistem monitoring berbasis IoT telah menunjukkan efektivitas dalam kontrol dan monitoring kondisi lingkungan (Arasy et al., 2023). Contohnya, sistem yang dibuat untuk kendali parameter suhu dan nutrisi tanaman bawang putih dengan menggunakan sensor sebagai indikator ukur parameter seperti pH dan suhu, serta mengirimkan data ke server untuk analisis lebih jauh untuk hasilnya (Arasy et al., 2023). Hal ini menunjukan teknologi IoT dapat diintegrasikan dengan lebih baik dalam sistem pertanian modern untuk meningkatkan efisiensi dan produktivitas.

Namun, kendala yang dihadapi adalah bagaimana cara mengelola dan membaca data yang diperoleh dari sensor-sensor tersebut. Penggunaan metode *machine learning* seperti *isolation forest* dapat menjadi solusi untuk mengatasi kendala yang dihadapi, dengan kemampuan untuk mendeteksi anomali secara otomatis dalam aliran data yang besar (Nugroho & Abdullah, 2022). Dengan demikian, penelitian ini bertujuan untuk mengembangkan sistem deteksi anomali yang dapat digunakan bersama dengan sistem smart aeroponik. Hal ini diharapkan dapat meningkatkan keandalan dan efektivitas sistem secara keseluruhan.

Dalam rangka mencapai tujuan penelitian ini, pendekatan yang sistematis akan diterapkan, mulai dari pengumpulan data, analisis, hingga pengembangan prototipe sistem deteksi anomali. Dengan memanfaatkan teknologi IoT dan metode pembelajaran mesin, diharapkan penelitian ini dapat memberikan kontribusi signifikan dalam pengembangan sistem

pertanian yang lebih cerdas dan efisien (Perteka et al., 2020; Husaini et al., 2021).

1.2 Rumusan Masalah

Dengan mempertimbangkan permasalahan yang telah diidentifikasi dalam latar belakang, berikut adalah beberapa rumusan masalah yang akan dikaji dalam penelitian ini:

1. Apa saja jenis anomali yang mungkin terjadi dalam sistem smart aeroponik yang menggunakan sensor IoT?
2. Bagaimana cara kerja metode Isolation Forest dalam mendeteksi anomali pada data yang dihasilkan oleh sensor IoT dalam sistem aeroponik?
3. Bagaimana cara mengembangkan prototipe sistem deteksi anomali yang dapat diimplementasikan dalam sistem smart aeroponik?

1.3 Batasan Masalah

1. Penelitian ini membatasi analisis pada parameter suhu, kelembaban, pH, dan konsentrasi nutrisi dalam sistem smart aeroponik berbasis sensor IoT.
2. Fokus utama penelitian adalah penerapan metode Isolation Forest untuk mendeteksi anomali pada data sensor IoT, tanpa membahas metode deteksi anomali lainnya.
3. Ruang lingkup penelitian terbatas pada sistem smart aeroponik berbasis IoT dan tidak mencakup sistem pertanian lain seperti hidroponik konvensional atau pertanian tanah.

1.4 Tujuan penelitian

Berdasarkan latar belakang dan perumusan masalah diatas, maka tujuan penelitian ini antara lain sebagai berikut:

1. Mengidentifikasi berbagai jenis anomali yang mungkin terjadi pada parameter lingkungan dalam sistem smart aeroponik berbasis sensor IoT, seperti suhu, kelembaban, pH, dan konsentrasi nutrisi.
2. Menganalisis cara kerja algoritma Isolation Forest dalam mendeteksi anomali pada data yang dihasilkan oleh sensor IoT.
3. Mengembangkan prototipe sistem deteksi anomali berbasis metode Isolation Forest yang dapat diimplementasikan dalam sistem smart aeroponik, untuk meningkatkan keandalan dan efisiensi pemantauan parameter lingkungan.

1.5 Manfaat penelitian

Manfaat dari penelitian ini secara garis besar terbagi menjadi dua, yaitu manfaat teoritis dan manfaat praktis. Adapun penjabarannya antara lain:

1.5.1. Manfaat Teoritis

Penelitian ini diharapkan mampu berkontribusi dalam menyediakan literatur tambahan terkait penerapan Isolation Forest dalam sistem IoT untuk pertanian, khususnya urban farming (pertanian di perkotaan). Selain sebagai penyedia literatur tambahan, diharapkan penelitian ini juga bermanfaat untuk memahami anomali data yang didasarkan pada beberapa parameter dalam pertanian sistem aeroponik, yakni parameter suhu, kelembaban, pH, dan nutrisi konsentrat. Pemahaman yang lebih baik pada adanya anomali data di dalam parameter-parameter ini diharapkan mampu membantu para petani perkotaan untuk mengambil keputusan secara matang dan tepat.

1.5.2. Manfaat Praktis

Penelitian ini menawarkan manfaat praktis dengan menyediakan solusi bagi petani untuk melakukan pemantauan kondisi sistem aeroponik dengan lebih efisien melalui teknologi IoT yang terintegrasi dengan algoritma Isolation Forest. Dengan adanya sistem ini, petani dapat secara otomatis mengawasi parameter penting seperti suhu, kelembaban, pH, dan konsentrasi nutrisi, sehingga mengurangi kebutuhan untuk pemantauan manual yang memakan waktu dan tenaga.

Selain itu, kemampuan untuk mendeteksi anomali secara dini memungkinkan petani untuk segera mengambil langkah-langkah perbaikan, sehingga mencegah kerugian yang mungkin disebabkan oleh kesalahan sensor atau perubahan parameter lingkungan yang tidak diinginkan. Dengan demikian, sistem ini tidak hanya meningkatkan efisiensi operasional, tetapi juga berkontribusi pada stabilitas pertumbuhan tanaman, yang mendukung produktivitas dan keberlanjutan dalam usaha pertanian.

1.6 Jadwal Penelitian

Tabel 1. 1 Jadwal Penelitian

No.	Nama Kegiatan	Bulan															
		Januari				Februari				Maret				April			
1	Identifikasi Masalah dan Studi Literatur																
2	Penyusunan Proposal dan Rancangan Penelitian																
3	Pengumpulan Dataset																
4	<i>Pre-processing</i> Data																
5	Implementasi Metode <i>Isolation Forest</i>																
6	Pengujian Model Deteksi Anomali																
7	Evaluasi Model																
8	Pengembangan Prototipe Sistem																
9	Uji Coba Sistem dan Perbaikan																
10	Penyusunan Laporan Akhir dan Presentasi																

BAB II

LANDASAN TEORI

Teori yang akan digunakan dalam penelitian ini adalah IoT (Internet of Things), khususnya sistem smart aeroponik berbasis IoT, anomali data yang ditemukan dari pengamatan parameter (suhu, kelembaban, pH, dan nutrisi konsentrat), dan teori deteksi anomali dengan menggunakan metode Isolation Forest.

2.1 Penelitian terdahulu

Tabel 2. 1 Penelitian terdahulu

Penulis (tahun)	Judul penelitian	Metode penelitian	Temuan utama
Prawiranegara et al. (2023)	Aeroponik Rumah Tanaman Dengan Sistem Tanam Benih Langsung Pada Tanaman Kangkung (Ipomoea aquatica Forssk.)	Sistem aeroponik, tanam benih langsung	Sistem aeroponik lebih efisien dalam penggunaan air, listrik, dan nutrisi dibandingkan sistem rakit apung. Meningkatkan keseragaman pertumbuhan tanaman kangkung.
Husaini et al. (2021)	Otomatisasi Monitoring Metode Budidaya Sistem Hidroponik dengan IoT	IoT, Android, MQTT, tenaga surya	Meningkatkan laju pertumbuhan tanaman hidroponik sebesar 21.67%. Efisiensi penggunaan panel

Penulis (tahun)	Judul penelitian	Metode penelitian	Temuan utama
	Berbasis Android MQTT dan Tenaga Surya		surya untuk sistem hidroponik.
Arasy et al. (2023)	Sistem Kendali Parameter Suhu dan Nutrisi Tanaman Bawang Putih pada Aeroponik menggunakan Metode Artificial Neural Network berbasis Arduino Uno	Sistem kontrol suhu dan nutrisi, ANN	Sistem dapat memprediksi durasi pompa dan kipas dengan akurasi 94%. Meningkatkan efisiensi pengaturan suhu dan nutrisi.
Nugroho & Husin (2022)	Analisis Performa Random Forest Menggunakan Normalisasi Atribut	Random Forest, Normalisasi Atribut	Meningkatkan akurasi klasifikasi dataset imbalanced hingga 99% dengan penggunaan normalisasi atribut.
Wulandari & Sumiar (2021)	Pengembangan Sistem Pengaturan Larutan Nutrisi Otomatis Pada Budidaya	Sistem otomatisasi, sensor TDS, ultrasonik	Sistem pengaturan otomatis larutan nutrisi dengan akurasi 98.28% pada sensor TDS. Menjaga volume air

Penulis (tahun)	Judul penelitian	Metode penelitian	Temuan utama
	Kentang Aeroponik		dan kadar nutrisi dalam rentang optimal.
Yepmo et al. (2024)	Leveraging an Isolation Forest to Anomaly Detection and Data Clustering	Isolation Forest, Anomaly Detection, Clustering	Menggunakan varian Isolation Forest untuk mendeteksi anomali sekaligus mengidentifikasi struktur data internal. Memperbaiki deteksi anomali dengan mempertahankan struktur data yang ada.
Goldstein & Uchida (2016)	A Comparative Evaluation of Unsupervised Anomaly Detection Algorithms for Multivariate Data	Deteksi Anomali Tanpa Pengawasan	Evaluasi 19 algoritma deteksi anomali tanpa pengawasan pada 10 set data yang berbeda, dengan rekomendasi algoritma berbasis tetangga terdekat dan deteksi anomali


Penulis (tahun)	Judul penelitian	Metode penelitian	Temuan utama
			berbasis pengelompokan.
Supriyono et al. (2023)	Sistem Monitoring Suhu, Kelembaban dan Kandungan Nutrisi Budidaya Tanaman Sawi Caisim Hidroponik Berdasarkan IoT	IoT, Sensor DHT11, Sensor TDS, Wemos D1 R1	Sistem untuk memonitor suhu, kelembaban, dan kandungan nutrisi tanaman sawi caisim hidroponik menggunakan sensor dan mikrokontroler, dengan tampilan data melalui aplikasi Android.
Vasiljević et al. (2025)	Federated Isolation Forest untuk Deteksi Anomali pada Sistem IoT Edge	Federated Isolation Forest (FLiForest) pada perangkat IoT edge berbasis MicroPython	Mencapai akurasi > 96 % dan presisi > 78 % dalam mendeteksi anomali suhu; cocok untuk perangkat dengan sumber daya terbatas
Moso et al. (2021)	Deteksi Anomali pada Data Stream untuk Pertanian Pintar	Isolation Forest untuk mendeteksi anomali pada citra SAR multispektral	Berhasil mendeteksi anomali pertumbuhan dan heterogenitas area tanaman gandum dan rapeseed dengan

Penulis (tahun)	Judul penelitian	Metode penelitian	Temuan utama
		(Sentinel-1 & 2)	lebih baik, melalui penggabungan citra multispektral
Perbedaan penelitian terdahulu dengan penelitian yang tertulis lakukan ialah:			
Ahmad Kurnia (2025)	Deteksi Anomali Pada Sistem Smart Aeroponik Menggunakan Algoritma <i>Isolation Forest</i> : Studi Kasus Sensor Iot	Tugas akhir	Hasil pembahasan menunjukkan bahwa penerapan algoritma Isolation Forest pada sistem smart aeroponik berbasis IoT mampu mendeteksi anomali data sensor (suhu, kelembapan, pH, dan nutrisi) secara akurat, sehingga meningkatkan keandalan monitoring dan mencegah gangguan pertumbuhan tanaman akibat kesalahan pembacaan sensor.”

2.2 Sistem Smart Aeroponik berbasis Internet of Things (IoT)

Pada pembahasan kali ini, akan dijabarkan teori tentang IoT dan sistem smart aeroponik berbasis IoT.

2.2.1. Internet of Things (IoT)



Gambar 2. 1 Mekanisme IoT

Sumber: Greenhouse UNINUS

Internet of Things (IoT) merupakan teknologi yang banyak digunakan dalam era Revolusi Industri 4.0. Teknologi ini menjadi dasar pengembangan aplikasi pintar di berbagai sektor, seperti industri, kesehatan, dan pertanian. Penerapan IoT perlu mempertimbangkan beberapa aspek, seperti biaya, energi, volume data, ketersediaan, latensi, dan mobilitas, dimana aspek-aspek tersebut disesuaikan dengan kebutuhan dan tujuan aplikasi (Radouche & Leghris, 2023).

Dari semua aspek tersebut, aspek mobilitas menjadi faktor utama yang mempengaruhi keefektifan aplikasi IoT, terutama dalam mendukung perangkat yang bergerak atau dinamis (Radouche & Leghris, 2023). Sistem yang mengintegrasikan IoT biasanya disebut sistem “pintar,” karena bertujuan untuk mengoptimalkan efisiensi, meningkatkan kinerja, memungkinkan kontrol jarak jauh, serta meminimalkan biaya operasional.

Dalam sektor pertanian, IoT dan *cloud computing* (komputasi awan) memainkan peran penting dalam meningkatkan efisiensi produksi tanaman hasil panen. Dengan bantuan IoT, aspek-aspek perawatan tanaman seperti

pengaturan biaya dan pemantauan kinerja alat-alat yang merawat tanaman akan lebih efektif karena solusi yang diberikan berbasis data yang akurat dan *real-time*.

Berdasarkan penjelasan di atas, IoT mampu meningkatkan efisiensi dan produktivitas, khususnya menghubungkan perangkat-perangkat fisik yang bisa dipantau secara langsung oleh petani. IoT mampu menciptakan sistem pertanian modern yang lebih responsif, ringkas, cerdas, hemat biaya, dan hemat energi.

2.2.2. Sistem Smart Aeroponik berbasis IoT

Pertanian urban, atau pertanian perkotaan, semakin populer seiring dengan meningkatnya kesadaran masyarakat perkotaan akan pentingnya kualitas makanan yang mereka konsumsi. Selain menyediakan makanan segar dan berkualitas, pertanian urban juga berperan dalam memenuhi kebutuhan pangan di wilayah perkotaan. Salah satu metode yang banyak digunakan dalam pertanian urban adalah metode aeroponik.

Metode aeroponik menggunakan udara sebagai media tanam, berbeda dengan metode tradisional maupun hidroponik. Dibandingkan dengan pertanian tradisional atau hidroponik, aeroponik menawarkan beberapa keunggulan, seperti efisiensi penggunaan ruang, penghematan air yang signifikan, dan potensi hasil panen yang lebih melimpah.

Metode aeroponik mengekspos akar tanaman pada tetesan aerosol yang mengandung larutan nutrisi. Hal ini meningkatkan ketersediaan oksigen di dalam zona akar serta menambah efisiensi penggunaan air. Untuk mengekspos akar tanaman pada tetesan aerosol ini, diperlukan sebuah alat yang dinamakan sprinkler nozzle. Tetesan aerosol ini mengandung berbagai mineral dan nutrisi yang dibutuhkan oleh tumbuhan.



Gambar 2. 2 Sistem Aeroponik

Sumber: Greenhouse UNINUS

Sistem smart aeroponik berbasis IoT merupakan sebuah sistem yang memungkinkan perangkat-perangkat pertanian untuk saling terhubung dan berkomunikasi, sehingga memungkinkan pengumpulan dan analisis data tanaman lebih akurat dan diambil secara *real-time*. Dalam konteks sistem aeroponik, teknologi ini memungkinkan pemantauan kondisi lingkungan seperti suhu, kelembaban, pH, dan konsentrasi nutrisi secara otomatis, yang sangat penting untuk pertumbuhan tanaman yang optimal (Prawiranegara, 2023). Dengan menggunakan sensor yang terintegrasi, petani dapat mengawasi parameter-parameter kritis dan mengambil tindakan yang diperlukan untuk menjaga kesehatan tanaman.

Integrasi sensor dalam sistem aeroponik berbasis IoT juga memberikan keuntungan dalam hal efisiensi penggunaan sumber daya. Teknologi IoT dapat meningkatkan efisiensi, produktivitas, dan keberlanjutan dalam praktik pertanian (Wulandari & Sumiar, 2021). Dengan memanfaatkan data yang dikumpulkan dari sensor, petani dapat

mengoptimalkan penggunaan air dan nutrisi, yang sangat penting dalam konteks pertanian berkelanjutan. Hal ini sejalan dengan penelitian yang menunjukkan bahwa sensor pertanian merupakan dasar dari teknologi IoT di bidang pertanian dan sangat penting untuk digitalisasi industri pertanian (Perteka et al., 2020).

Selain itu, sistem smart aeroponik berbasis IoT juga dapat meningkatkan responsivitas terhadap perubahan kondisi lingkungan. Dengan kemampuan untuk mendeteksi anomali secara dini, sistem ini memungkinkan petani untuk segera mengambil tindakan korektif sebelum masalah menjadi lebih serius. Penelitian menekankan pentingnya penggabungan data dari berbagai sensor untuk meningkatkan akurasi dan efektivitas dalam pengelolaan pertanian (Husaini et al., 2021). Dengan demikian, penerapan teknologi IoT dalam sistem aeroponik tidak hanya meningkatkan efisiensi operasional, tetapi juga membantu menjaga stabilitas pertumbuhan tanaman.

Namun, penerapan IoT dalam sistem pertanian juga menghadapi tantangan, terutama terkait dengan keamanan dan privasi data. Banyak perangkat IoT rentan terhadap serangan siber, sehingga penting untuk mengembangkan kerangka kerja keamanan yang dapat melindungi data dan infrastruktur pertanian dari ancaman yang ada (Nugroho & Abdullah, 2022). Oleh karena itu, penelitian ini juga akan mempertimbangkan aspek keamanan dalam penerapan teknologi IoT di sistem smart aeroponik.

Secara keseluruhan, sistem smart aeroponik berbasis IoT menawarkan banyak keuntungan, mulai dari peningkatan efisiensi operasional hingga pengelolaan sumber daya yang lebih baik. Dengan menghubungkan perangkat fisik dan memungkinkan mereka untuk berkomunikasi dan bertukar data, IoT dapat menciptakan sistem pertanian yang lebih responsif dan cerdas. Penelitian ini bertujuan untuk mengeksplorasi lebih lanjut bagaimana teknologi IoT dapat diintegrasikan

dengan metode deteksi anomali untuk menciptakan sistem pertanian yang lebih cerdas dan efisien.

2.3 Anomali

2.3.1. Anomali dalam Pengumpulan Data

Anomali merupakan suatu istilah yang merujuk pada penyimpangan dari sesuatu yang sudah ada. Dalam konteks ini, anomali ditujukan pada sebuah data atau pola yang menyimpang secara signifikan dari kondisi atau situasi yang diharapkan. Adapun dalam konteks pertanian, khususnya sistem smart aeroponik, anomali dapat muncul sebagai perubahan mendadak dalam parameter lingkungan yang dapat mempengaruhi pertumbuhan tanaman.

Deteksi anomali penting untuk mencegah kerugian yang disebabkan oleh kondisi yang mempengaruhi kesehatan tanaman seperti faktor suhu, kelembaban, pH, dan konsentrasi nutrisi yang ternyata tidak bisa ditoleransi tanaman. Menurut Wulandari dan Sumiar (2021), dalam sistem pertanian, deteksi anomali dapat membantu dalam mengidentifikasi masalah yang mungkin timbul akibat kesalahan pengukuran atau fluktuasi parameter lingkungan (Prawiranegara, 2023). Dengan demikian, pemantauan yang efektif terhadap anomali dapat meningkatkan efisiensi dan produktivitas pertanian.

2.4 Parameter yang Diamati dalam Mendeteksi Anomali

2.4.1. Suhu

Suhu adalah salah satu parameter lingkungan yang paling kritis dalam pertanian. Suhu yang terlalu tinggi atau terlalu rendah dapat mempengaruhi metabolisme dan pertumbuhan tanaman. Penelitian oleh Suryatini et al. (2020) menunjukkan bahwa pemantauan suhu secara *real-time* dalam sistem hidroponik dapat membantu petani mengatur kondisi

lingkungan untuk pertumbuhan optimal tanaman (Wulandari & Sumiar, 2021). Dengan menggunakan sensor suhu, petani dapat mengidentifikasi perubahan suhu yang tidak diinginkan dan mengambil tindakan korektif sebelum masalah menjadi lebih serius.

2.4.2. Kelembaban

Kelembaban juga merupakan faktor penting yang mempengaruhi pertumbuhan tanaman. Kelembaban yang tidak tepat dapat menyebabkan stres pada tanaman, yang dapat mengakibatkan penurunan hasil panen. Penelitian oleh Prawiranegara (2023) menekankan bahwa pemantauan kelembaban tanah dan udara sangat penting untuk memastikan tanaman mendapatkan kondisi yang ideal untuk pertumbuhan (Perteka et al., 2020). Dengan teknologi IoT, kelembaban dapat dipantau secara otomatis, sehingga petani dapat melakukan penyesuaian yang diperlukan dengan cepat.

2.4.3. pH

pH larutan nutrisi adalah parameter penting lainnya yang mempengaruhi ketersediaan nutrisi bagi tanaman. pH yang tidak sesuai dapat menghambat penyerapan nutrisi, yang berdampak negatif pada pertumbuhan tanaman. Penelitian oleh Safrimawan (2019) menjelaskan bahwa pemantauan pH secara berkala dalam sistem hidroponik dapat membantu petani menjaga kualitas larutan nutrisi dan memastikan tanaman mendapatkan nutrisi yang tepat (Husaini et al., 2021). Dengan sistem monitoring yang baik, perubahan pH dapat dideteksi lebih awal, memungkinkan tindakan perbaikan yang cepat dan tepat.

2.4.4. Konsentrasi Nutrisi (ppm)

Konsentrasi nutrisi dalam larutan, yang diukur dalam satuan ppm (parts per million), adalah indikator penting dari kesehatan tanaman. Nutrisi yang tidak mencukupi atau berlebihan dapat menyebabkan masalah pertumbuhan. Penelitian oleh Anggraini et al. (2023) menunjukkan bahwa

sistem monitoring yang efektif dapat membantu petani mengatur konsentrasi nutrisi dengan tepat, sehingga meningkatkan hasil pertanian (Nugroho & Abdullah, 2022). Dengan memantau konsentrasi nutrisi secara real-time, petani dapat memastikan bahwa tanaman mendapatkan nutrisi yang diperlukan untuk pertumbuhan optimal.

Dengan memahami anomali dan parameter yang diamati dalam mendeteksi anomali, penelitian ini bertujuan untuk mengembangkan sistem yang lebih efisien dalam memantau dan mengelola kondisi pertanian, khususnya dalam konteks sistem aeroponik berbasis IoT.

2.5 *Machine Learning*

Machine Learning (ML) adalah cabang dari kecerdasan buatan yang berfokus pada pengembangan algoritma dan model statistik yang memungkinkan komputer untuk melakukan analisis dan pengambilan keputusan berdasarkan data, tanpa memerlukan instruksi eksplisit. Hal ini berarti bahwa melalui pengalaman, komputer dapat belajar untuk mengenali pola dalam data dan membuat prediksi yang didasarkan pada pola-pola tersebut (Lesouple et al., 2021). Dalam konteks sistem smart aeroponik berbasis sensor Internet of Things (IoT), penerapan ML bertujuan untuk menganalisis data lingkungan secara otomatis dan mendeteksi anomali yang dapat mengindikasikan adanya gangguan dalam sistem atau kondisi lingkungan yang tidak ideal. Analisis ini penting untuk meningkatkan efisiensi dan produktivitas sistem aeroponik.

2.5.1. Unsupervised Learning untuk Deteksi Anomali

Unsupervised Learning adalah teknik dalam ML yang berfokus pada pembelajaran dari data tanpa menggunakan label. Metode ini bertujuan untuk menemukan struktur tersembunyi dalam data, serta mendiagnosis anomali yang mungkin tidak biasa atau signifikan. Dalam konteks deteksi anomali, unsupervised learning berperan penting dalam


mengidentifikasi data yang secara signifikan berbeda dari pola mayoritas yang ada (Issa et al., 2024).

2.6 Metode Isolation Forest untuk Mendeteksi Anomali

2.6.1. Pengertian *Isolation Forest*

Isolation Forest adalah algoritma pembelajaran mesin yang dirancang khusus untuk mendeteksi anomali dalam dataset. Metode ini diperkenalkan oleh Liu et al. pada tahun 2008 dan telah menjadi salah satu teknik yang populer dalam deteksi anomali karena efisiensinya dalam menangani data besar dan kemampuannya untuk bekerja tanpa memerlukan asumsi distribusi data tertentu (Wulandari & Sumiar, 2021). Isolation Forest bekerja dengan cara membangun sejumlah pohon keputusan secara acak, di mana setiap pohon berfungsi untuk "mengisolasi" titik data. Anomali, yang biasanya lebih jarang dan berbeda dari data normal, akan terisolasi lebih cepat dalam pohon-pohon ini, sehingga memiliki panjang jalur yang lebih pendek dibandingkan dengan data normal (Wulandari & Sumiar, 2021).

2.6.2. Mekanisme Kerja *Isolation Forest*



Gambar 2. 3 Ilustrasi Model *Isolation Forest*

Sumber: datrics.ai

Proses deteksi anomali dengan *Isolation Forest* dimulai dengan pemilihan acak subset dari data dan membangun pohon keputusan berdasarkan pemisahan acak dari fitur-fitur yang ada. Setiap pemisahan menciptakan cabang baru dalam pohon, dan titik data yang lebih mudah terisolasi akan memiliki kedalaman yang lebih kecil dalam pohon tersebut. Dengan menghitung kedalaman rata-rata dari semua pohon untuk setiap titik data, algoritma ini dapat memberikan skor anomali, di mana skor yang lebih tinggi menunjukkan kemungkinan bahwa titik tersebut adalah anomali (Wulandari & Sumiar, 2021). Keunggulan utama dari metode ini adalah kemampuannya untuk mendeteksi anomali dalam dataset yang besar dan kompleks dengan kecepatan yang tinggi.

2.6.3. Keunggulan *Isolation Forest*

Isolation Forest memiliki beberapa keunggulan dibandingkan dengan metode deteksi anomali lainnya. Pertama, algoritma ini memiliki kompleksitas waktu yang linear, yang membuatnya sangat efisien untuk dataset besar. Kedua, *Isolation Forest* tidak memerlukan pelatihan model yang rumit dan dapat dengan mudah diimplementasikan dalam berbagai aplikasi (Wulandari & Sumiar, 2021). Ketiga, metode ini tidak bergantung pada asumsi distribusi data, sehingga dapat digunakan pada berbagai jenis data, termasuk data dengan dimensi tinggi dan noise yang signifikan. Hal ini menjadikannya pilihan yang menarik untuk aplikasi di berbagai bidang, termasuk pertanian, di mana data yang dikumpulkan dari sensor seringkali memiliki variasi yang besar.

2.6.4. Aplikasi *Isolation Forest* dalam Deteksi Anomali

Dalam konteks pertanian, *Isolation Forest* dapat digunakan untuk mendeteksi anomali dalam parameter lingkungan yang diukur oleh sensor. Misalnya, Shao et al. menerapkan metode ini untuk mengidentifikasi anomali dalam data yang berkaitan dengan pertumbuhan tanaman, seperti fluktuasi suhu dan kelembaban yang tidak biasa (Wulandari & Sumiar,

2021). Dengan memantau parameter seperti suhu, kelembaban, pH, dan konsentrasi nutrisi, petani dapat menggunakan Isolation Forest untuk mendeteksi perubahan yang tidak diinginkan dan mengambil tindakan preventif. Pemantauan ini juga mampu meningkatkan efisiensi operasional dan menjaga kesehatan tanaman.

2.6.5. Tantangan dalam Penerapan Isolation Forest

Meskipun Isolation Forest menawarkan banyak keuntungan, tetap terdapat beberapa tantangan dalam penerapannya. Misalnya, adanya data yang tidak seimbang yang dapat mempengaruhi kinerja algoritma. Puggini dan McLoone (2018) menunjukkan bahwa pemilihan variabel yang tepat dan pengurangan dimensi dapat meningkatkan interpretabilitas model dan kinerja deteksi anomali (Perteka et al., 2020). Oleh karena itu, penting untuk mempertimbangkan langkah-langkah pra-pemrosesan data sebelum menerapkan Isolation Forest dalam konteks sistem pertanian.

Dengan memahami metode Isolation Forest dan aplikasinya dalam mendeteksi anomali, penelitian ini bertujuan untuk mengembangkan sistem yang lebih efisien dalam memantau dan mengelola kondisi pertanian, khususnya dalam konteks sistem aeroponik berbasis IoT.

BAB III

ANALISIS DAN PERANCANGAN SISTEM

Pada bab ini, akan dijelaskan desain penelitian dan perancangan sistem. Bab ini menjelaskan metode yang akan digunakan dalam penelitian. Pemilihan metode penelitian disesuaikan dengan jenis data yang dibutuhkan dan akan menggunakan paling relevan dalam menjawab rumusan masalah. Pada bab ini, juga akan dijelaskan jenis penelitian yang digunakan, populasi dan sampel data, instrumen penelitian yang digunakan, prosedur pengumpulan data.

3.1 Desain penelitian

Desain Penelitian mencakup Kerangka Berpikir, Jenis Penelitian, Pendekatan Penelitian, Variabel Penelitian, dan Alur Penelitian. Kerangka Berpikir menggambarkan alur pemikiran yang dimulai dari identifikasi masalah, dampaknya, solusi yang ditawarkan, implementasi, evaluasi, hingga hasil yang diharapkan. Jenis Penelitian menjelaskan tipe penelitian yang digunakan serta fokus kajiannya. Pendekatan Penelitian menguraikan metode yang diterapkan dalam penelitian ini, Variabel Penelitian menjelaskan variabel-variabel yang digunakan di dalam penelitian, sedangkan Alur Penelitian memberikan gambaran umum mengenai tahapan penelitian secara sistematis.


3.2 Kerangka berpikir

Dalam sistem smart aeroponik, sensor IoT berperan penting dalam memantau kelembaban, suhu, pH, dan kadar nutrisi tanaman. Namun, anomali pada sensor akibat kesalahan pengukuran, gangguan sinyal, atau kerusakan perangkat dapat menyebabkan data tidak akurat. Jika tidak ditangani secepatnya, anomali ini dapat menurunkan keandalan sistem, mengganggu pengambilan keputusan, dan bahkan menyebabkan kegagalan sistem secara keseluruhan.

Untuk mengatasi masalah ini, penelitian ini mengusulkan penggunaan *Isolation Forest* sebagai metode deteksi anomali. Algoritma berbasis pohon keputusan ini dapat mengidentifikasi anomali dengan efisien, menjadikannya solusi yang sesuai untuk sistem IoT *real-time*. Implementasi metode ini mencakup pengumpulan data sensor, *preprocessing*, serta analisis menggunakan *Isolation Forest* untuk membedakan data normal dan anomali.

Evaluasi model dilakukan menggunakan metrik *Precision*, *Recall*, dan *F1-Score* guna memastikan efektivitas deteksi anomali. Diharapkan model yang dihasilkan mampu meningkatkan keandalan sistem smart aeroponik dengan mendeteksi anomali secara akurat, sehingga mendukung pertumbuhan tanaman yang optimal dan meminimalkan risiko kegagalan akibat kesalahan sensor.

Berikut ini alur Kerangka Berpikir penelitian ini:



Gambar 3. 1 Kerangka Berpikir

3.3 Jenis penelitian

Penelitian ini menggunakan metode penelitian kuantitatif. Penelitian kuantitatif digunakan karena metode ini yang paling sesuai, dengan fokus pada pengukuran dan analisis data numerik untuk mengidentifikasi pola dan hubungan antar variabel, baik variabel bebas maupun variabel terikat. Pada konteks penelitian ini, metode yang digunakan untuk mengidentifikasi dan mendeteksi anomali adalah metode algoritma Isolation Forest, dan data-data yang digunakan merupakan data yang dihasilkan oleh sensor IoT, dimana untuk menganalisis data tersebut memerlukan pendekatan berbasis data numerik yang dapat diukur dan dianalisis secara statistik (Arliani, 2021; Acoci et al., 2023; Suhara, 2022).

Selain alasan diatas, metode kuantitatif juga dipilih karena penelitian ini juga akan mengevaluasi apakah algoritma Isolation Forest efektif dalam mendeteksi anomali, dan metode ini juga memungkinkan peneliti untuk mengumpulkan data dalam jumlah besar untuk mengukur performa algoritma tersebut dalam konteks sistem smart aeroponik (Oktavia, 2023; Acoci et al., 2023). Selain itu, penelitian kuantitatif dapat diaplikasikan pada skala yang lebih luas, yang mendukung penerapan IoT dalam berbagai sistem pertanian (Arliani, 2021; Suhara, 2022).

3.4 Pendekatan penelitian

Pendekatan penelitian ini menggunakan metode studi kasus. Metode studi kasus sangat relevan dan cocok untuk mendeteksi anomali pada sistem smart aeroponic dengan menggunakan menggunakan algoritma Isolation Forest. Pendekatan ini memungkinkan peneliti untuk menganalisis fenomena anomali dalam konteks yang lebih mendalam dan spesifik, serta memberikan pemahaman yang lebih komprehensif mengenai dinamika antar variabel dalam sistem smart aeroponik.

Pemilihan pendekatan studi kasus ini didasarkan pada sistem aeroponik yang kompleks dengan melibatkan berbagai variabel serta interaksi antara sensor IoT, lingkungan tumbuh, dan algoritma Isolation Forest sebagai algoritma yang mendeteksi anomali. Dengan menggunakan pendekatan ini, peneliti dapat fokus pada satu atau beberapa sistem aeroponik tertentu, sehingga pengumpulan data dapat lebih spesifik dan analisis yang dilakukan lebih mendalam terkait proses deteksi anomali dan proses mengatasi anomali tersebut. Sebagai contoh, penelitian oleh Wulandari dan Sumiar (2021) menunjukkan bagaimana sistem smart dalam budidaya kentang dapat dioptimalkan untuk meningkatkan hasil pertanian. Temuan ini juga sejalan dengan penelitian Iriani dan Lazuli (2018), yang menekankan pentingnya pemantauan berbasis IoT dalam sistem pertanian modern, untuk pengembangan sistem pertanian dari pengumpulan data real-time dari sensor-sensor yang ada untuk dianalisis lebih dalam.

Selain sebagai metode untuk mempelajari berbagai fenomena antar variabel, studi kasus juga memungkinkan peneliti untuk mengidentifikasi pola dan anomali yang mungkin tidak nampak karena banyaknya data. Hal ini krusial dalam deteksi anomali, karena variasi kecil dalam data sensor dapat menunjukkan masalah yang lebih besar dalam sistem. Lebih lanjut, penelitian Sunarto (2023) tentang deteksi anomali menggunakan Extended Isolation Forest menyatakan bahwa pendekatan berbasis studi kasus dapat memberikan wawasan yang lebih dalam tentang bagaimana algoritma dapat diadaptasi untuk menangani berbagai variasi data yang kompleks.

Dengan demikian, pendekatan studi kasus dalam penelitian ini tidak hanya memberikan pemahaman yang lebih dalam tentang deteksi anomali dalam sistem smart aeroponik, tetapi juga memungkinkan pengembangan solusi yang lebih efektif dan aplikatif berdasarkan data empiris dari sistem yang diteliti.

3.5 Variabel penelitian

Pada penelitian ini, terdapat beberapa variabel yang diklasifikasikan sebagai variabel independen, variabel dependen, dan variabel kontrol. Berikut ini penjelasannya:

3.5.1. Variabel independen (variabel bebas)

Variabel independen adalah variabel-variabel yang bisa diukur, agar bisa dilihat pengaruhnya terhadap variabel dependen, dan data-data dari variabel ini nantinya digunakan sebagai sumber data untuk model Isolation Forest dalam mendeteksi anomali. Variabel-variabel ini diambil dari sensor IoT. Variabel-variabel independen dalam penelitian ini antara lain:

- Suhu udara (°C): Suhu adalah parameter penting yang mempengaruhi pertumbuhan tanaman dalam sistem aeroponik (Rizki, 2025).
- Kelembaban udara (%): Kelembaban udara dan kelembaban larutan nutrisi sangat mempengaruhi kesehatan tanaman (Suryatini et al., 2020).
- pH larutan nutrisi: Diukur dalam skala pH. pH yang tidak sesuai dapat menyebabkan penyerapan nutrisi yang buruk oleh tanaman (Rizki, 2025).
- Kadar nutrisi (EC - Electrical Conductivity, mS/cm): Mengukur jumlah padatan terlarut dalam larutan nutrisi, yang penting untuk menentukan konsentrasi nutrisi yang tersedia bagi tanaman (Rizki, 2025).

3.5.2. Variabel dependen (variabel terikat)

Variabel dependen atau variabel terikat adalah variabel yang hasilnya dipengaruhi oleh variabel bebas. Dalam penelitian ini, variabel dependen adalah:

- Deteksi anomali: Indikasi apakah suatu data dari sensor IoT mengalami anomali atau tidak.
 - Kelas Normal (0): Data sensor dalam rentang normal.
 - Kelas Anomali (1): Data sensor terdeteksi mengalami penyimpangan signifikan.
- Tingkat akurasi deteksi anomali: Diukur dalam persentase (%), menunjukkan seberapa baik model Isolation Forest dapat mendeteksi anomali dalam data sensor (Sunarto, 2023).
- Jumlah anomali yang teridentifikasi: Menghitung jumlah kejadian anomali yang terdeteksi dalam periode tertentu (Sunarto, 2023).
- Waktu respons deteksi anomali: Waktu yang dibutuhkan untuk mendeteksi

Pemilihan variabel-variabel tersebut, baik variabel bebas maupun variabel terikat, didasarkan pada relevansi dan signifikansi mereka dalam konteks sistem smart aeroponik. Data sensor IoT memberikan informasi yang diperlukan untuk memantau kondisi lingkungan dan kesehatan tanaman, yang sangat penting dalam sistem aeroponik. Dengan menggunakan algoritma Isolation Forest, penelitian ini bertujuan untuk mengidentifikasi anomali yang dapat mengindikasikan masalah dalam sistem, seperti fluktuasi suhu yang ekstrem atau perubahan pH yang tidak normal.

3.6 Alur penelitian


Penelitian ini bertujuan untuk membuat sistem deteksi anomali melalui serangkaian tahapan yang disusun secara terstruktur. Proses penelitian ini dimulai dari mengidentifikasi anomali di dalam data yang dihasilkan sensor IoT (sensor suhu, kelembaban, pH, dan kadar nutrisi), dimana anomali ini dapat mempengaruhi keandalan sistem smart aeroponik. Data yang diperoleh bisa berupa data historis maupun data real-time, sesuai dengan pendekatan yang diambil dalam penelitian (Sari, 2024). Setelah

pengumpulan data, tahap berikutnya adalah *preprocessing*, yang mencakup pembersihan data untuk menangani nilai yang hilang atau tidak valid, serta normalisasi data agar semua parameter berada dalam skala yang konsisten (Dewa, 2024).

Setelah data siap, model untuk deteksi anomali dibuat menggunakan algoritma Isolation Forest. Algoritma ini dirancang untuk membedakan antara data normal dan anomali berdasarkan pola distribusi yang ada dalam data (Putra et al., 2022). Model tersebut kemudian dievaluasi dengan menggunakan berbagai metrik, seperti akurasi, *precision*, *recall*, dan F1-score, untuk menilai seberapa baik kinerjanya dalam mendeteksi anomali secara tepat (Wulandari & Sumiar, 2021). Tahap ini penting untuk memastikan bahwa model tersebut dapat diandalkan saat diterapkan dalam situasi nyata.

Hasil dari evaluasi tersebut akan dianalisis dan divisualisasikan untuk memberikan pemahaman yang lebih dalam mengenai pola anomali yang terdeteksi, kemungkinan penyebabnya, serta langkah-langkah yang bisa diambil untuk memperbaiki sistem (Iriani & Lazuli, 2018). Penelitian kemudian diakhiri dengan interpretasi hasil dan rekomendasi untuk pengembangan sistem lebih lanjut, dengan tujuan untuk meningkatkan keandalan keseluruhan sistem smart aeroponik. Keseluruhan alur penelitian ini dirancang untuk memberikan solusi yang sistematis dan berbasis data terhadap tantangan deteksi anomali dalam sistem aeroponik berbasis IoT (Sunarto, 2023).

Diagram Alur Penelitian



Gambar 3. 2 Alur Penelitian

3.7 Perancangan sistem

3.7.1. Deskripsi sistem

Beberapa komponen utama dalam sistem ini mencakup sensor, aktuator dan kontroler. Adapun jenis komponen yang digunakan antara lain:

3.7.2. Sensor

Sensor berperan penting dalam mendeteksi berbagai parameter lingkungan yang mempengaruhi pertumbuhan tanaman dalam sistem aeroponik. Jenis sensor yang digunakan dalam sistem ini adalah:

- 1) DFRobot Gravity: Analog pH Sensor / Meter Pro Kit V2

Sensor ini digunakan untuk mengukur tingkat keasaman (pH) larutan nutrisi dalam sistem aeroponik. Dengan akurasi yang tinggi, sensor ini dapat terhubung dengan Arduino atau mikrokontroler lainnya untuk pemantauan secara *real-time*.



Gambar 3. 3 Sensor PH

Sumber: (<https://images.app.goo.gl/dHWxNYRSsR1iKUQS9>)

2) DFRobot: Analog TDS Sensor/Meter for Arduino

Sensor ini berfungsi untuk mengukur Total Dissolved Solids (TDS) dalam larutan nutrisi, yang memberikan indikasi tentang jumlah nutrisi terlarut dalam air.




Gambar 3. 4 Sensor TDS

Sumber: (<https://images.app.goo.gl/dcNWXXsKs8VSfAZ18>)

3) DFRobot: Waterproof DS18B20 Digital Temperature Sensor Kit

Sensor ini digunakan untuk mengukur suhu air dalam sistem aeroponik. Dengan desain tahan air, sensor ini dapat beroperasi dalam kondisi kelembaban tinggi tanpa resiko kerusakan.



Gambar 3. 5 Sensor DS18B20

Sumber: (<https://images.app.goo.gl/syjLCjMGPGnw6y5x8>)

4) Sensor Kelembaban SHT20

Sensor ini digunakan untuk memantau tingkat kelembaban di sekitar tanaman, memastikan bahwa kondisi optimal untuk pertumbuhan tanaman dapat terjaga.



Gambar 3. 6 Sensor SHT2O

Sumber: (<https://images.app.goo.gl/BshEQJEamY1M7hMm6>)

3.7.3. Aktuator

Aktuator bertugas untuk menjalankan perintah dari sistem kontrol guna mengatur lingkungan pertumbuhan tanaman. Aktuator yang digunakan dalam sistem ini meliputi:

1) Peristaltic Pump Dosing Pump 12V DC

Pompa ini berfungsi untuk mengatur aliran larutan nutrisi yang diberikan kepada tanaman, memastikan distribusi nutrisi yang tepat sesuai dengan kebutuhan tanaman.



Gambar 3. 7 Pompa

Sumber: (<https://images.app.goo.gl/4rsSKXLK5B2HrT5G9>)

2) Mist Nozzle 0.15 mm

Nozzle ini digunakan untuk menghasilkan kabut larutan nutrisi yang disemprotkan langsung ke akar tanaman. Dengan kemampuan menghasilkan kabut halus, nozzle ini meningkatkan efisiensi penyerapan nutrisi oleh akar.



Gambar 3. 8 nozzle

Sumber: (<https://images.app.goo.gl/uQqzNB9DDaTn9Wyu5>)

3.7.4. Kontroler

Sistem kontroler berfungsi untuk mengolah data dari sensor dan mengontrol aktuator berdasarkan algoritma yang telah diprogram. Kontroler yang digunakan dalam sistem ini adalah:

- 1) Modul LILYGO T-RelayS3 T-Relay S3 ESP32-S3

Modul ini berfungsi sebagai pusat pengendali dari sistem smart aeroponik, membaca data dari sensor dan mengontrol aktuator secara otomatis. Dengan konektivitas Wi-Fi dan Bluetooth, ESP32-S3 memungkinkan pemantauan dan pengendalian sistem dari jarak jauh melalui aplikasi atau platform IoT.



Gambar 3. 9 Mikrokontroler

sumber:(<https://images.app.goo.gl/LZ5gKvjWrJaZx51j6>)

Dengan kombinasi komponen-komponen ini, sistem smart aeroponik dapat beroperasi secara otomatis dalam memantau dan mengontrol kondisi pertumbuhan tanaman. Integrasi antara sensor, aktuator, dan kontroler memungkinkan penggunaan air dan nutrisi yang lebih efisien, serta meningkatkan produktivitas tanaman dalam sistem aeroponik.

3.8 Metode deteksi anomali

3.8.1. Implementasi isolation forest

3.8.1.1. Pengumpulan data

Sumber data yang digunakan meliputi data historis yang diambil dari berbagai sensor yang terpasang di lingkungan pertanian. Data ini mencakup informasi mengenai parameter lingkungan seperti suhu, kelembaban, pH tanah, dan kadar nutrisi. Data historis ini sangat penting karena memberikan gambaran tentang pola dan tren yang terjadi dalam sistem, yang dapat digunakan untuk analisis lebih lanjut dan pengambilan keputusan yang lebih baik dalam pengelolaan pertanian.

Metode pengumpulan data dalam sistem smart aeroponik dilakukan melalui dua pendekatan utama: pemantauan *real-time* dan penggunaan data dari bank data *open-source*. Pemantauan *real-time* dilakukan dengan menggunakan sensor IoT yang terhubung ke jaringan, yang memungkinkan pengumpulan data secara terus-menerus dan langsung dari lingkungan pertanian. Sensor ini mengumpulkan data mengenai kondisi tanah dan tanaman, yang kemudian dikirim ke server untuk analisis lebih lanjut.

Selain itu, data dari bank data *open-source* juga digunakan untuk melengkapi analisis. Data ini dapat mencakup informasi dari berbagai sumber, seperti penelitian sebelumnya, laporan cuaca, dan data agronomi yang telah dikumpulkan oleh lembaga penelitian atau

organisasi pertanian. Penggunaan data *open-source* ini memungkinkan peneliti dan praktisi untuk mengakses informasi yang lebih luas dan relevan, yang dapat meningkatkan akurasi dan efektivitas model yang dikembangkan.

3.8.1.2. Pra-pemrosesan data

3.8.1.2.1. Data cleansing

a) Missing value

proses untuk identifikasi nilai yang hilang merupakan langkah dasar dalam pemrosesan data. Ketika menggunakan data sensor untuk mendeteksi anomali, tantangan dapat muncul karena berbagai faktor, seperti kerusakan sensor atau masalah dalam pemrosesan data. Beberapa teknik yang umum digunakan untuk menangani nilai yang hilang termasuk imputasi, di mana nilai yang sulit ditentukan diperkirakan menggunakan nilai lain dari dataset. Metode ini dapat digunakan untuk menghitung median, rata-rata, atau modus dari fitur serupa untuk memperkirakan data berkualitas tinggi (Fahim & Sillitti, 2019; Zhao et al., 2023).

b) Menghapus duplikasi

Aspek penting berikutnya dari pembersihan data adalah deduplikasi. Entri duplikat dapat muncul akibat kesalahan yang dibuat selama pengumpulan data atau saat mengintegrasikan kumpulan data dari berbagai sumber. Kehadiran duplikat dapat mendistorsi analisis dan mengurangi keakuratan model. Dengan demikian, mengidentifikasi dan menghilangkan rekaman duplikat sangat penting sebelum melanjutkan ke tahap analisis berikutnya. Metode umum untuk mendeteksi duplikat melibatkan perbandingan entri menggunakan fungsi hash atau penggunaan teknik berbasis aturan untuk menemukan entri yang memiliki nilai identik di semua fitur (Omol, 2024; Zhao et al., 2019)

c) Transformasi data

Selama fase pra-pemrosesan deteksi anomali yang menggunakan metode Isolation Forest, langkah penting melibatkan standarisasi data melalui Teknik minmax scaller. Metode ini menyesuaikan data untuk mencapai nilai rata-rata 0 dan deviasi standar 1, yang penting karena banyak algoritma pembelajaran mesin, termasuk Isolation Forest, bekerja lebih efektif saat data mempertahankan skala yang seragam. Saat fitur dalam kumpulan data menunjukkan rentang nilai yang sangat berbeda, seperti suhu yang diukur dalam derajat Celcius dibandingkan dengan tingkat pH yang berkisar dari 0 hingga 14, model cenderung mengutamakan fitur dengan rentang yang lebih luas, sering kali mengabaikan yang lain. Standarisasi memastikan bahwa setiap fitur berkontribusi secara merata, sehingga meningkatkan kemampuan model untuk mengidentifikasi anomali dengan presisi yang lebih tinggi.

$$X_{scaled} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Di mana:

- X adalah nilai asli dari fitur.
- Xmin adalah nilai minimum fitur tersebut.
- Xmax adalah nilai maksimum fitur tersebut.
- Xscaled adalah nilai yang sudah dinormalisasi.

d) Menyimpan data yang telah diproses

Setelah semua langkah pembersihan dan transformasi data selesai, data yang telah diproses perlu disimpan untuk digunakan dalam pelatihan model. Format penyimpanan dapat bervariasi, tetapi format

yang umum digunakan termasuk CSV, JSON, atau database SQL. Menyimpan data dalam format yang terstruktur dan mudah diakses akan memudahkan proses analisis lebih lanjut dan pengembangan model deteksi anomali (Gong et al., 2019; Gang et al., 2023).

3.8.1.2.2. Membuat model

Setelah fase pra-pemrosesan data selesai dilaksanakan, langkah selanjutnya yang perlu melibatkan pembuatan model deteksi anomali menggunakan algoritma Isolation Forest. Model khusus ini dipilih karena kemampuannya dalam mengidentifikasi anomali dalam data yang tidak berlabel, ciri yang sering diamati dalam sistem sensor IoT (Pathak et al., 2021; Chatterjee & Ahmed, 2022).

a) Menetapkan Nilai Kontaminasi

Parameter utama dalam model Hutan Isolasi adalah nilai *contamination parameter*, yang mencerminkan proporsi data anomali yang diharapkan. Menetapkan nilai ini secara akurat sangat penting, karena dapat mempengaruhi efektivitas model dalam mengidentifikasi anomali secara signifikan. Biasanya, nilai kontaminasi diperoleh dari keahlian domain atau analisis awal data yang tersedia. Dalam kerangka sistem aeroponik cerdas, nilai ini dapat dipastikan dengan memeriksa data historis dan pola yang dikenali dari kondisi normal dan anomali yang mungkin muncul (azizah et al., 2023).

Misalnya, jika analisis awal menunjukkan bahwa sekitar 5% dari data historis mencakup anomali, nilai kontaminasi dapat ditetapkan pada 0,05. Penetapan nilai ini secara akurat membantu model dalam meningkatkan deteksi anomali dan menurunkan tingkat kesalahan klasifikasi (Zakariah, 2023).

b) Menghitung Skor Anomali

Anomaly Score memiliki peran yang sangat penting dalam mengidentifikasi nilai-nilai yang menyimpang dari data normal, yang dapat mengindikasikan adanya masalah dalam sistem. Algoritma Isolation Forest berfungsi dengan cara mengisolasi data yang dianggap anomali dengan memisahkan titik data yang jaraknya jauh dari distribusi data utama. Anomaly score dihitung berdasarkan panjang jalur (path length), yang mengukur seberapa jauh titik data harus dipisahkan dalam struktur pohon Isolation Tree. Titik data yang lebih mudah diisolasi (anomali) akan memiliki panjang jalur yang lebih pendek, sementara data yang normal akan memiliki panjang jalur yang lebih panjang. Skor ini memungkinkan penilaian terhadap seberapa besar kemungkinan suatu data merupakan anomali.(azizah et al., 2023).

$$S(x, n) = 2 \frac{E(h(x))}{c(n)} \quad (2)$$

Sumber: azizah et al., 2023

Keterangan rumus:

$H(x)$: path length

$E(h(x))$: rata-rata path length dari setiap isolation tree.

$C(n)$: rata-rata $h(x)$ dari nilai variabel ke- n

Algoritma Isolation Forest secara otomatis melakukan perhitungan skor anomali selama pelatihan model. Setelah pelatihan selesai, metode `decision_function` dari pustaka Scikit-learn dapat digunakan untuk mengambil skor anomali untuk setiap titik data dalam kumpulan data. Titik data yang menunjukkan skor anomali berada di bawah ambang batas tertentu, yang ditetapkan menurut nilai kontaminasi, akan diklasifikasikan sebagai anomali (Alsaedi et al., 2020). Dengan menggunakan model machine learning isolation forest,

seseorang dapat mencapai hasil deteksi anomali yang tepat dan dapat diandalkan untuk sistem aeroponik pintar berbasis sensor IoT, yang penting untuk memastikan kesehatan tanaman dan efektivitas operasional (Ngo et al., 2020).

3.8.1.2.3. Evaluasi model

setelah dilakukan preprocessing data dan pembuatan model machine learning metode isolation forest, model dikembangkan dan dilakukan pengujian pada data. evaluasi menjadi tahapan atau fase yang penting untuk mengidentifikasi model yang baik untuk deteksi anomali. tujuan dari evaluasi merupakan untuk menentukan model efektif untuk membandingkan data normal dan anomali. fase evaluasi dalam bentuk grafik terdiri dari beberapa metrik yang digunakan sebagai berikut:

a) Precision

$$precision = \frac{True\ positives}{True\ positives + false\ positives} \quad (3)$$

rumus diatas menjelaskan mengenai dimana True Positives (TP) adalah jumlah anomali yang berhasil dideteksi oleh model, sedangkan False Positives (FP) adalah jumlah data normal yang dikategorikan sebagai data anomali. Precision yang dihasilkan tinggi menunjukkan bahwa model klasifikasi yang efektif sangat penting untuk aplikasi seperti sistem aeroponik pintar, di mana error dalam deteksi anomali dapat berdampak negatif pada keselamatan kerja dan efisiensi operasional. Namun, referensi yang digunakan oleh Ullah et al. (2021) dan Ghosh et al. (2023) tidak sepenuhnya membahas masalah akurasi dalam konteks sistem aeroponik pintar yang menggunakan algoritma Isolation Forest.

b) Recall

setelah dilakukan uji coba dengan precision, metrik selanjutnya adalah metode recall yang dimana recall bertujuan untuk mengukur kemampuan model dalam mendeteksi yang sebenarnya ada. berikut rumus yang berkaitan dengan metode recall:

$$precision = \frac{True\ positives}{True\ positives + false\ negatives} \quad (4)$$

True Positives (TP) adalah data anomali yang berhasil terdeteksi, sedangkan False Negatives (FN) adalah data anomali yang tidak terdeteksi oleh model dan dikategorikan sebagai normal. Recall yang hasilnya tinggi menunjukkan bahwa model dapat mendeteksi anomali terbesar dalam data, yang sangat penting untuk memastikan integritas dan keselamatan sistem aeroponik cerdas. Oleh karena itu, evaluasi memori memberikan informasi yang berguna tentang beberapa model efektif untuk mengidentifikasi potensi masalah yang mungkin mempengaruhi hasil penelitian.

c) F1-score

F1-score merupakan metrik penting dalam evaluasi model deteksi anomali, terutama dalam konteks sistem smart aeroponik yang menggunakan sensor IoT. Metrik ini sangat berguna dalam situasi di mana distribusi data tidak seimbang, yaitu ketika jumlah data normal jauh lebih banyak dibandingkan dengan data anomali. Dalam konteks ini, F1-score dihitung dengan rumus sebagai berikut:

$$F1 - SCORE = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (5)$$

dengan TP (True Positives) adalah jumlah anomali yang terdeteksi dengan benar, FP (False Positives) adalah jumlah anomali

yang salah terdeteksi, dan FN (False Negatives) adalah jumlah anomali yang tidak terdeteksi.

F1-score memberikan gambaran yang lebih akurat tentang kinerja model dalam mendeteksi anomali dibandingkan dengan matrik lain seperti akurasi, terutama ketika data anomali jarang terjadi. Yaqoob et al. menekankan bahwa F1-score memberikan informasi yang lebih komprehensif dalam konteks deteksi anomali (Yaqoob et al., 2023). Selain itu, penelitian oleh Fourure et al. menunjukkan bahwa F1-score sangat sensitif terhadap tingkat kontaminasi dalam dataset, yang dapat mempengaruhi interpretasi hasil evaluasi model (Fourure et al., 2021). Oleh karena itu, pemilihan metode evaluasi yang tepat sangat penting untuk mendapatkan hasil yang valid.

Secara menyeluruh, F1-score merupakan metode metrik yang penting dalam proses evaluasi model deteksi anomali, terutama dalam konteks sistem smart aeroponik yang menggunakan sensor IoT. Dengan mempertimbangkan keseimbangan antara presisi dan recall, serta menerapkan teknik-teknik terbaru dalam machine learning, sistem dapat lebih efektif dalam mendeteksi anomali yang dapat mempengaruhi hasil panen.

3.9 Analisis dan interpretasi hasil

Dalam proses sebelumnya yang telah dilakukan dan telah melalui proses membuat model machine learning metode isolation forest selesai, selanjutnya untuk melanjutkan proses uji coba dan analisis hasil dari model machine learning isolation forest yang telah dibuat. Apa model menghasilkan data yang baik atau masih tetap perlu pengembangan agar akurasi model lebih baik, berikut tabel untuk uji coba dengan beberapa parameter yang akan di uji coba

Tabel 3. 1 Form Uji

Timestamp	Suhu (°C)	Kelembaban (%)	Ph	Nutrisi (Ppm)	Prediksi	Detail Anomali

BAB IV

HASIL DAN PEMBAHASAN

4.1 Pembuatan Model Deteksi Anomali Menggunakan Isolation Forest

Pada fase ini, proses pembuatan model untuk mendeteksi anomali dilakukan dengan memanfaatkan algoritma Isolation Forest. Algoritma ini dipilih karena efisiensinya dalam mengidentifikasi data yang secara signifikan berbeda (anomalous) di dalam dataset yang besar, terutama yang melibatkan banyak variabel. Mekanisme kerja algoritma ini melibatkan konstruksi beberapa pohon keputusan yang bertujuan untuk "memisahkan" data yang dianggap tidak biasa dari data yang normal. Dengan demikian, data yang lebih mudah untuk dipisahkan dari kelompok lainnya akan diidentifikasi sebagai anomali.

4.1.1. Data Sensor yang Digunakan

Tabel 4. 1 Sampel Data Yang Digunakan

Timestamp	Suhu (°C)	Kelembaban (%)	Ph	Nutrisi (Ppm)
07/04/2023 00:11	27.8	94.9	4.52	206.8
07/04/2023 04:31	39.0	67.9	5.68	211.9
07/04/2023 08:43	13.3	52.1	5.91	209.4
07/04/2023 12:01	17.6	27.2	7.95	209.6
07/04/2023 16:14	12.6	94.1	7.64	240.9
08/04/2023 00:43	23.1	32.5	7.25	124.3
08/04/2023 04:25	15.3	75.3	6.57	139.5
08/04/2023 08:38	42.5	94.2	7.62	166.4
08/04/2023 12:49	43.1	43.5	7.75	174.8

```

import pandas as pd
from tabulate import tabulate

# Membaca file CSV
df = pd.read_csv('/content/file_output_terbaru_dengan_timestamp.csv')

# Ambil 5 data awal dan akhir
df_head = df.head()
df_tail = df.tail()

# Cetak dengan tabel bergaris
print("=== Data Awal (head) ===")
print(tabulate(df_head, headers='keys', tablefmt='grid'))

print("\n=== Data Akhir (tail) ===")
print(tabulate(df_tail, headers='keys', tablefmt='grid'))

```

```

=== Data Awal (head) ===
+-----+-----+-----+-----+-----+
| timestamp | suhu | kelembaban | ph | nutrisi |
+-----+-----+-----+-----+
| 0 | 07/04/2023 04:31 | 50.18 | 88 | 6.23 | 240.09 |
+-----+-----+-----+-----+
| 1 | 07/04/2023 05:31 | 21.63 | 77 | 7.17 | 382.77 |
+-----+-----+-----+-----+
| 2 | 07/04/2023 06:31 | 23.06 | 74 | 7.38 | 218.11 |
+-----+-----+-----+-----+
| 3 | 07/04/2023 07:31 | 26.24 | 71 | 6.88 | 382.05 |
+-----+-----+-----+-----+
| 4 | 07/04/2023 08:31 | 21.49 | 68 | 7.58 | 235.03 |
+-----+-----+-----+-----+

=== Data Akhir (tail) ===
+-----+-----+-----+-----+-----+
| timestamp | suhu | kelembaban | ph | nutrisi |
+-----+-----+-----+-----+
| 16906 | 11/03/2025 14:31 | 22.82 | 88 | 5.92 | 162.73 |
+-----+-----+-----+-----+
| 16907 | 11/03/2025 15:31 | 22.19 | 89 | 6.12 | 112.36 |
+-----+-----+-----+-----+
| 16908 | 11/03/2025 16:31 | 23.65 | 90 | 5.71 | 120.53 |
+-----+-----+-----+-----+
| 16909 | 11/03/2025 17:31 | 23.49 | 91 | 5.99 | 52.39 |
+-----+-----+-----+-----+
| 16910 | 11/03/2025 18:31 | 24.71 | 88 | 6.03 | 328.57 |
+-----+-----+-----+-----+

```

Gambar 4. 1 Upload Data Dan Print Data

Data yang dipakai untuk pelatihan dan pengujian model deteksi anomali ini diambil dari sensor Internet of Things (IoT) yang terpasang dalam sistem aeroponik pintar. Sensor-sensor tersebut berfungsi untuk mengukur sejumlah parameter lingkungan yang krusial, termasuk suhu, kelembaban, pH, dan kadar nutrisi dalam sistem. Data yang diperoleh memiliki format numerik dan dirazai dalam interval waktu tertentu, mencakup rentang waktu beberapa bulan demi mendapatkan gambaran yang lebih komprehensif mengenai kondisi yang terukur.

4.1.2. Proses Preprocessing Data

Sebelum data dapat dimanfaatkan dalam pelatihan model, serangkaian langkah preprocessing diperlukan untuk menyiapkan data agar sesuai dengan persyaratan algoritma yang akan digunakan. Proses ini mencakup beberapa tahapan, antara lain:

4.1.2.1. Cleaning

Pada tahap cleaning, dilakukan penghapusan kolom yang tidak relevan dalam dataset, seperti kolom timestamp, yang berisi informasi waktu yang tidak dibutuhkan dalam analisis deteksi anomali pada parameter lingkungan. Penghapusan kolom timestamp ini bertujuan untuk menyederhanakan dataset dan memastikan bahwa data yang digunakan hanya berfokus pada parameter sensor yang relevan, seperti suhu, kelembaban, pH, dan konsentrasi nutrisi.

```
# Buang kolom 'timestamp' dan simpan ke variabel baru
sensor_value = df.drop(columns=['timestamp'])

# Tampilkan hasilnya
print("=== Data Sensor (tanpa kolom timestamp) ===")
display(sensor_value)
```

	suhu	kelembaban	ph	nutrisi
0	50.18	80.0	6.23	240.09
1	21.63	77.0	7.17	382.77
2	23.06	74.0	7.38	218.11
3	26.24	71.0	6.88	382.05
4	21.49	68.0	7.58	235.03
...	...	...	...	...
16906	22.82	88.0	5.92	162.73
16907	22.19	89.0	6.12	112.36
16908	23.65	90.0	5.71	120.53
16909	23.49	91.0	5.99	52.39
16910	24.71	80.0	6.03	328.57

16911 rows x 4 columns

Gambar 4. 2 Proses Hapus Kolom

Tabel 4. 2 Hasil Hapus Kolom Pada Data

Suhu (°C)	Kelembaban (%)	Ph	Nutrisi (Ppm)
50.18	80	6.23	240.09
21.63	77	7.17	382.77
23.06	74	7.38	218.11
26.24	71	6.88	382.05
21.49	68	7.58	235.03
50.18	65	8.83	332.72
22.39	62	5.9	205.34
21.34	59	5.69	182.72
25.66	56	6.61	335.04

4.1.2.2. Normalisasi

Data sensor yang diterapkan dalam sistem aeroponik pintar disesuaikan sehingga semua parameter berada dalam skala yang seragam. Langkah ini diambil untuk mencegah dominasi salah satu parameter selama proses pelatihan model akibat perbedaan skala yang signifikan. Sebagai ilustrasi, gambar yang ada menunjukkan penerapan normalisasi menggunakan MinMaxScaler, yang mengubah setiap nilai parameter seperti suhu, kelembaban, pH, dan konsentrasi nutrisi agar berada dalam rentang 0 hingga 1. Proses normalisasi ini menjamin bahwa semua parameter memiliki kontribusi yang sama dalam pelatihan model, yang pada akhirnya berperan dalam meningkatkan akurasi dan kestabilan model dalam mendeteksi anomali. Setelah fase normalisasi, dataset siap untuk digunakan dalam proses pelatihan lebih lanjut tanpa ada parameter yang lebih dominan daripada yang lainnya.

```
# 4. Normalisasi data
scaler = MinMaxScaler()
scaled_data = scaler.fit_transform(sensor_value)

# konversi hasil normalisasi menjadi DataFrame agar mudah dibaca
scaled_df = pd.DataFrame(scaled_data, columns=sensor_value.columns)

# Tampilkan hasil normalisasi
print("=== Data Setelah Normalisasi ===")
display(scaled_df)

# Simpan hasil normalisasi ke file CSV (optional)
scaled_df.to_csv("/content/scaled_sensor_value terbaru.csv", index=False)

# Informasikan lokasi file disimpan
print("Hasil normalisasi disimpan di '/content/scaled_sensor_value terbaru.csv'")
```

=== Data Setelah Normalisasi ===

	suhu	kelembaban	ph	nutrisi
0	0.877090	0.855263	0.454992	0.587110
1	0.334726	0.815789	0.608838	0.939702
2	0.361892	0.776316	0.643208	0.532793
3	0.422302	0.736842	0.561375	0.937923
4	0.332067	0.697368	0.675941	0.574606
...	...	...	...	...
16906	0.357333	0.960526	0.404255	0.395937
16907	0.345365	0.973684	0.436989	0.271462
16908	0.373100	0.986842	0.369885	0.291652
16909	0.370061	1.000000	0.415712	0.123264
16910	0.393237	0.855263	0.422259	0.805763

16911 rows x 4 columns
Hasil normalisasi disimpan di '/content/scaled_sensor_value terbaru.csv'

Gambar 4. 3 Hasil Normalisasi Data

4.1.2.3. Training dan Parameterisasi Model Isolation Forest

Setelah pengolahan data yang diperoleh dari sensor selesai, model Isolation Forest dan autoencoder dilatih secara simultan dengan tujuan mendeteksi keberadaan anomali dalam data melalui pola-pola yang terkandung di dalamnya. Model autoencoder berfungsi untuk menciptakan representasi yang lebih mendalam dari data masukan, proses ini mencakup kompresi data menjadi bentuk kodifikasi dengan dimensi yang lebih rendah, serta rekonstruksi data tersebut ke bentuk semula. Dalam konteks ini, pelatihan dilakukan dalam beberapa epoch, yang masing-masing merupakan siklus pembelajaran yang memungkinkan model untuk terus memperbarui dan meningkatkan akurasi dalam identifikasi anomali.

Pada permulaan setiap epoch, autoencoder diatur untuk memperoleh representasi fitur dari data masukan, sedangkan Isolation Forest beroperasi pada representasi yang dihasilkan oleh autoencoder. Proses ini diinisiasi dengan penerapan parameter

penting pada kedua model; untuk Isolation Forest, parameter tersebut meliputi jumlah pohon keputusan (*nestimators*), *jumlah maksimum sampel yang dapat dimasukkan ke dalam pohon* (*maxsamples*), serta tingkat kontaminasi (*contamination*) yang menentukan proporsi data yang diperkirakan sebagai anomali. Di sisi lain, autoencoder menggunakan fungsi loss yang menghitung perbedaan antara data asli dan keluaran hasil rekonstruksi, dengan tujuan utama mengurangi kesalahan rekonstruksi.

Selama pelaksanaan setiap epoch, autoencoder beradaptasi untuk mengkodekan data menjadi representasi yang lebih sederhana dan efisien, yang bertujuan mengurangi noise dan meningkatkan perhatian pada fitur-fitur yang relevan. Setelah proses penguasaan representasi berlangsung, Isolation Forest menganalisis titik-titik data dengan membangun hutan yang terdiri dari pohon-pohon keputusan yang mengidentifikasi anomali berdasarkan jarak dari pola normal yang telah ditentukan. Evaluasi dilakukan pada akhir setiap epoch untuk mengoptimalkan parameter dan mekanisme internal, sehingga memperbaiki kemampuan model dalam mendeteksi outlier yang mungkin tidak teridentifikasi dalam siklus sebelumnya.

Hasil dari pelatihan terintegrasi ini memungkinkan model untuk mengklasifikasikan data sensor ke dalam dua kategori; data yang terdeteksi sebagai anomali akan dilabeli dengan 1, sementara yang dianggap normal diberikan label 0. Dengan demikian, kolaborasi antara autoencoder dan Isolation Forest tidak hanya meningkatkan akurasi dalam mendeteksi anomali tetapi juga memperkuat representasi fitur yang digunakan dalam proses deteksi. Oleh karena itu, dapat disimpulkan bahwa kombinasi kedua pendekatan ini mengoptimalkan proses pelatihan dan memperbaiki performa deteksi anomali dalam konteks aplikasi yang nyata.

```
[ ] # Langkah 2: Latih Autoencoder untuk Mendeteksi Anomali
input_dim = X_train.shape[1] # Dimensi data
encoding_dim = 32 # Ukuran encoding (lebih kecil)

# Definisi arsitektur Autoencoder
input_layer = Input(shape=(input_dim,))
encoded = Dense(encoding_dim, activation='relu')(input_layer)
decoded = Dense(input_dim, activation='sigmoid')(encoded)

autoencoder = Model(input_layer, decoded)
autoencoder.compile(optimizer='adam', loss='mean_squared_error')

# Latih Autoencoder dengan epoch 1800
autoencoder.fit(X_train, X_train, epochs=1800, batch_size=256, shuffle=True, initial_epoch=721)

# Menyimpan model Autoencoder setelah pelatihan selesai
autoencoder.save('autoencoder_model.h5')
print("Model Autoencoder disimpan di 'autoencoder_model.h5'")

# -----
# Hitung Rekonstruksi Error pada Data Pelatihan
# -----
# Prediksi data dengan Autoencoder (hasil rekonstruksi)
reconstructed_data_train = autoencoder.predict(X_train)
reconstruction_error_train = np.mean(np.abs(X_train - reconstructed_data_train), axis=1)

# Tampilkan distribusi rekonstruksi error untuk data pelatihan
plt.figure(figsize=(10, 6))
plt.hist(reconstruction_error_train, bins=50, color='skyblue', edgecolor='black')
plt.title("Distribution of Reconstruction Error on Training Data")
plt.xlabel("Reconstruction Error")
plt.ylabel("Frequency")
plt.show()
```

```
Epoch 998/1800      2ms/step - loss: 5.1837e-04
53/53              2ms/step - loss: 5.1837e-04
Epoch 999/1800      2ms/step - loss: 5.2030e-04
53/53              2ms/step - loss: 5.2030e-04
Epoch 1000/1800     2ms/step - loss: 5.2412e-04
53/53              2ms/step - loss: 5.2412e-04
Epoch 1001/1800     2ms/step - loss: 5.1819e-04
53/53              2ms/step - loss: 5.1819e-04
Epoch 1002/1800     2ms/step - loss: 5.2392e-04
53/53              2ms/step - loss: 5.2392e-04
Epoch 1003/1800     2ms/step - loss: 5.2351e-04
53/53              2ms/step - loss: 5.2351e-04
Epoch 1004/1800     2ms/step - loss: 5.2182e-04
53/53              2ms/step - loss: 5.2182e-04
Epoch 1005/1800     2ms/step - loss: 5.1599e-04
53/53              2ms/step - loss: 5.1599e-04
Epoch 1006/1800     2ms/step - loss: 5.2317e-04
53/53              2ms/step - loss: 5.2317e-04
Epoch 1007/1800     2ms/step - loss: 5.2515e-04
53/53              2ms/step - loss: 5.2515e-04
Epoch 1008/1800     2ms/step - loss: 5.2637e-04
53/53              2ms/step - loss: 5.2637e-04
Warning: abal>You are saving your model as an h5 file via 'model.save()' or 'keras.saving.save_model(model)'
```

Gambar 4. 4 proses epoch

```
# 5. Training Isolation Forest
model = IsolationForest(contamination=0.5, n_estimators=100, max_samples=0.8, random_state=42)
model.fit(scaled_data)

# 7. Prediksi Anomali dengan model yang telah dilatih
predictions = model.predict(scaled_data) # -1 untuk anomali, 1 untuk normal

# 8. Menampilkan hasil prediksi (misal, jumlah anomali yang terdeteksi)
num_anomalies = sum(predictions == -1)
num_normal = sum(predictions == 1)

# Menampilkan hasil pelatihan model
print("=== Model Isolation Forest telah Dilatih ===")
print(f"Jumlah anomali yang terdeteksi: {num_anomalies}")
print(f"Jumlah data normal: {num_normal}")

# Menambahkan hasil prediksi ke dalam DataFrame untuk laporan
sensor_value['predictions'] = predictions

# Tampilkan DataFrame dengan prediksi
print("\n=== Data dengan Prediksi Anomali ===")
display(sensor_value.head()) # Menampilkan 5 baris pertama

# 6. Simpan model dan scaler ke file
joblib.dump(model, f'content/isolation_forest_model.pkl')
joblib.dump(scaler, f'content/scaler.pkl')

# Informasikan lokasi file disimpan
print("\nModel dan scaler telah disimpan!")
print(f"Model disimpan di '{content/isolation_forest_model.pkl}'")
print(f"Scaler disimpan di '{content/scaler.pkl}'")
```

```
=== Model Isolation Forest telah Dilatih ===
Jumlah anomali yang terdeteksi: 8455
Jumlah data normal: 8456

=== Data dengan Prediksi Anomali ===
   suhu  kelembapan  ph  nutrisi  predictions
0  50.18      80.0  6.23   240.09           -1
1  21.63      77.0  7.17   382.77           -1
2  23.06      74.0  7.38   218.11            1
3  26.24      71.0  6.88   382.05           -1
4  21.48      68.0  7.58   235.03            1

Model dan scaler telah disimpan!
Model disimpan di 'content/isolation_forest_model.pkl'
Scaler disimpan di 'content/scaler.pkl'
```

Gambar 4. 5 Hasil Train Model

4.1.2.4. Evaluasi Kinerja Model

Setelah model Isolation Forest dilatih dan diuji, hasil evaluasi menunjukkan performa model dalam mendeteksi anomali pada dataset sensor IoT yang digunakan. Proses evaluasi ini diperkuat dengan penggunaan teknik K-fold cross-validation yang berfungsi untuk meningkatkan keandalan penilaian model. Dalam proses K-fold, dataset dibagi menjadi K subset yang berbeda, di mana model dilatih pada K-1 subset dan diuji pada subset yang tersisa. Proses ini diulang K kali, dengan setiap subset berperan sebagai data uji satu kali, sehingga memberikan gambaran yang lebih komprehensif mengenai performa model dan meminimalisir bias dalam pemilihan data pelatihan dan pengujian.

Beberapa metrik yang digunakan untuk mengevaluasi model ini antara lain Precision, Recall dan F1-Score, yang dijabarkan sebagai berikut. Precision mengukur proporsi prediksi positif yang benar di antara semua prediksi positif yang dibuat, sementara Recall mengukur proporsi prediksi positif yang benar dibandingkan dengan total aktual positif. F1-Score merupakan harmonisasi dari Precision dan Recall yang memberikan indikasi tentang keseimbangan antara kedua matriks tersebut.

Proses evaluasi ini juga membantu dalam menentukan apakah performa model konsisten di seluruh subset dan mengidentifikasi potensi kekurangan yang mungkin tidak tampak tanpa pendekatan validasi yang ketat. Dengan penerapan K-fold cross-validation, evaluasi performa model tidak hanya lebih akurat tetapi juga lebih objektif, memberikan gambaran yang lebih baik mengenai kemampuannya dalam mendeteksi anomali di dunia nyata.

	precision	recall	f1-score	support
Normal (0)	0.61	0.85	0.71	9469
Anomali (1)	0.76	0.46	0.57	9469
accuracy			0.66	18938
macro avg	0.69	0.66	0.64	18938
weighted avg	0.69	0.66	0.64	18938

Gambar 4. 6 Hasil Evaluasi Model

a) Classification Report


Hasil dari klasifikasi menunjukkan nilai precision, recall, dan f1-score untuk kelas "True" (anomali) dan "False" (data normal). Berikut adalah hasil yang didapatkan:

- Precision: Model ini berhasil mengidentifikasi 61% dari data normal dengan tepat, sementara untuk data anomali, akurasi deteksinya mencapai 76%. Meskipun nilai precision untuk kedua kelas masih di bawah 100%, model menunjukkan kemampuan yang baik dalam membedakan antara kedua kategori dengan cukup seimbang.
- Recall: Kinerja model dalam mendeteksi data normal terbilang sangat memuaskan, dengan nilai recall sebesar 85% untuk kelas "False". Di sisi lain, nilai recall untuk kelas "True" adalah 46%, yang menunjukkan adanya ruang untuk perbaikan, meskipun model masih mampu mendeteksi sebagian besar data relevan.
- F1-Score: Untuk kelas "True" (anomalies), f1-score yang diperoleh adalah 0.57, yang mencerminkan adanya keseimbangan yang memadai antara precision dan recall dalam mendeteksi anomali. Di sisi lain, f1-score untuk kelas "False" lebih tinggi, yaitu 0.71, yang menunjukkan model mampu menjaga keseimbangan yang baik dalam


mengidentifikasi data normal, dengan memperhatikan keseimbangan antara kedua matriks tersebut.

Secara keseluruhan, akurasi dari model ini mencapai 66%, yang mengindikasikan bahwa performanya terbilang baik meskipun terdapat tantangan dalam menyeimbangkan deteksi antara kedua kelas. Oleh karena itu, model ini dapat dianggap efektif, karena berhasil mendeteksi sebagian besar data normal dengan tingkat ketepatan yang cukup tinggi; hal ini menjadi penting dalam konteks aplikasi praktis tertentu.

b) Confusion Matrix



Gambar 4. 7 Confusion Matrix



Gambar 4. 8 Matrix Evaluasi

Berdasarkan analisis yang dilakukan melalui matriks konfusi dan hasil dari evaluasi model menggunakan K-Fold Cross Validation, berikut adalah rincian pembaruan hasil yang diperoleh dari model deteksi anomali:


- True Positives (TP): Model ini berhasil mengklasifikasikan 4.335 data anomali dengan akurat sebagai anomali. Hal ini menunjukkan bahwa model cukup efisien dalam mendeteksi data anomali meskipun ada tantangan dalam meningkatkan tingkat recall untuk kelas anomali.
- False Positives (FP): Sebanyak 1.379 data normal salah terdeteksi sebagai anomali. Meskipun model mampu mendeteksi sebagian besar data normal dengan tepat, masih ada kecenderungan model untuk salah mengklasifikasikan beberapa data normal sebagai anomali, yang perlu diperbaiki.
- False Negatives (FN): Model tidak mampu mendeteksi 5.134 data anomali yang seharusnya diidentifikasi sebagai anomali. Ini menunjukkan bahwa meskipun model cukup baik, masih ada ruang untuk meningkatkan kemampuan deteksi untuk data anomali yang lebih sulit dikenali.

- True Negatives (TN): Model berhasil dengan baik mengklasifikasikan 8.090 data normal dengan tepat sebagai data normal. Meskipun ini menunjukkan kinerja yang cukup baik dalam mendeteksi data normal, masih ada beberapa kesalahan dalam mendeteksi anomali.

Berdasarkan grafik yang menunjukkan hasil evaluasi melalui K-Fold Cross-Validation, nilai precision, recall, dan f1-score mengalami variasi antar fold, namun tetap menunjukkan hasil yang stabil secara keseluruhan. Precision lebih tinggi untuk kelas anomalies (True), sedangkan recall lebih tinggi untuk kelas normal (False), yang menunjukkan bahwa model lebih baik dalam mendeteksi data normal daripada data anomali. Secara keseluruhan, nilai recall untuk kategori anomali mencapai 46%, yang menunjukkan adanya tantangan dalam meningkatkan kemampuan model untuk mendeteksi lebih banyak data anomali.

Namun, precision untuk kelas anomali cukup tinggi, yaitu 76%, yang berarti model dapat mendeteksi data anomali dengan tepat meskipun ada beberapa kesalahan deteksi (false negatives). Model ini memiliki potensi yang baik dalam deteksi anomali, namun perbaikan lebih lanjut dalam mengurangi False Positives dan False Negatives akan meningkatkan kinerja model, terutama untuk data anomali.

c) Dunn Index



Gambar 4. 9 Matrix Dunn Index

Hasil analisis dari Centroid Distance Matrix memberikan gambaran mengenai jarak antara centroid pada dua kluster yang dianalisis. Nilai Dunn Index yang diperoleh mencapai 19.3514, menandakan adanya visibilitas yang sangat baik antara kedua kluster tersebut. Berikut adalah penjelasan terkait analisis hasil matriks jarak centroid:

- Untuk kluster 0, tidak terdapat data yang terdeteksi berasal dari kluster yang sama (0), sedangkan semua data dari kluster 1 terklasifikasikan di kluster yang berbeda (41).
- Sedangkan pada kluster 1, sebanyak 41 data diidentifikasi dengan benar sebagai bagian dari kluster ini, akan tetapi tidak ada satupun data dari kluster 0 yang terdeteksi berada dalam kluster ini (0).

Interpretasi: Nilai tinggi dari Dunn Index (19.3514) menunjukkan bahwa kluster-kluster yang terbentuk memiliki divergensi yang kuat dan jelas, dengan divergensi yang baik antara

kluster 0 dan kluster 1. Matriks ini menunjukkan bahwa setiap kluster terpisah dengan efektif, yang mencerminkan keefektifan model clustering dalam membedakan dua kelompok yang berbeda. Secara keseluruhan, matriks ini menunjukkan kinerja clustering yang memuaskan, dengan tingkat penanda antar kluster yang jelas dan konsisten. Dunn Index yang lebih tinggi mengkonfirmasi bahwa model ini memiliki kapabilitas yang baik untuk memisahkan data berdasarkan kriteria yang telah ditetapkan.

4.2 Identifikasi dan Klasifikasi Anomali Berdasarkan Hasil Deteksi

Model Isolation Forest digunakan untuk mendeteksi anomali dalam data sensor yang dikumpulkan dari sistem smart aeroponik. Setelah model berhasil dilatih, data yang telah diproses (misalnya suhu, kelembaban, pH, dan konsentrasi nutrisi) dianalisis untuk mengidentifikasi titik-titik data yang dianggap sebagai anomali.

4.2.1. Hasil Deteksi Anomali

Setiap titik data sensor akan diklasifikasikan menjadi dua kategori:

- Normal: Data yang berada dalam batas yang wajar atau pola yang dikenal dari sistem aeroponik.
- Anomali: Data yang menyimpang jauh dari pola normal, yang menunjukkan adanya ketidaksesuaian yang perlu ditindaklanjuti, seperti kerusakan sensor atau perubahan parameter yang tidak diinginkan.

Untuk memberikan gambaran yang lebih jelas tentang hasil deteksi, berikut adalah tabel klasifikasi anomali yang menunjukkan bagaimana data sensor dikategorikan oleh model:


Tabel 4. 3 Hasil Uji

timestamp	Suhu (°C)	Kelembaban(%)	Ph	Nutrisi(Ppm)	is_anomaly
01/01/2025 00:21	20.88	82.0	6.5	1724.9	1
01/01/2025 06:34	23.98	81.45	7.5	1874	1
02/01/2025 10:52	22.78	82.07	6.43	1324.4	0
02/01/2025 11:01	23.86	83.15	5.56	1619.5	0
02/01/2025 11:48	24.17	83.73	5.58	1468	0
02/01/2025 20:23	25.6	80.15	6.9	1696.9	1
10/04/2025 21:46	25.6	79.08	20.0	1275.7	1
02/01/2025 23:06	21.02	82.95	7.42	1506.8	0
02/01/2025 23:30	25.63	83.53	5.53	1519	0

4.2.2. Analisis Hasil Deteksi Anomali

Dari tabel di atas, dapat dilihat bahwa model berhasil mengidentifikasi beberapa titik data sebagai anomali, seperti suhu yang lebih tinggi dari yang seharusnya, seperti yang terlihat pada beberapa timestamp dengan suhu yang melebihi rentang normal. Deteksi ini sangat penting karena suhu yang tidak normal dapat menunjukkan adanya masalah dalam sistem, seperti ketidakseimbangan dalam pengaturan suhu.

Selain itu, beberapa nilai konsentrasi nutrisi yang lebih tinggi juga terdeteksi sebagai anomali. Hal ini dapat mengindikasikan adanya kesalahan dalam sistem pemberian nutrisi yang dapat berdampak pada kesehatan tanaman jika tidak segera ditangani. Pentingnya deteksi anomali ini adalah untuk memastikan sistem berfungsi dengan baik, mencegah kerusakan lebih lanjut, dan menjaga stabilitas operasional.



Gambar 4. 10 Heatmap Matrix

Heatmap korelasi digunakan untuk memahami hubungan antar fitur pada data sensor smart aeroponik. Korelasi dinyatakan dalam nilai -1 hingga 1:

Tabel 4. 4 Tabel Korelasi Hasil Pengujian


Sensor 1	Sensor 2	Korelasi	Interpretasi
Suhu	Kelembaban	0.063	Hampir tidak berkorelasi
Suhu	pH	0.006	Tidak ada korelasi yang berarti
Suhu	Nutrisi	-0.051	Korelasi sangat lemah negatif
Kelembaban	pH	0.0039	Tidak ada korelasi
Kelembaban	Nutrisi	0.11	Korelasi lemah positif (cenderung naik bersama)
pH	Nutrisi	-0.062	Korelasi sangat lemah negatif

- **1** : Hubungan sangat kuat dan positif (naik bersama)
- **0** : Tidak ada korelasi
- **-1** : Hubungan sangat kuat tapi negatif (satu naik, satunya turun)

Berdasarkan hasil heatmap korelasi:

- Tidak terdapat korelasi yang signifikan antara sensor suhu, kelembaban, pH, dan nutrisi.
- Setiap fitur bersifat relatif independen, sehingga dapat berkontribusi secara unik dalam proses deteksi anomali.
- Model seperti Isolation Forest sangat cocok digunakan, karena tidak mengandalkan hubungan antar fitur yang kuat.

Visualisasi heatmap ini mendukung pendekatan deteksi anomali berbasis *unsupervised learning* yang fokus pada pola distribusi individual tiap fitur.



Gambar 4. 11 Hasil Deteksi Korelasi Data Uji

Grafik ini mencerminkan pola perubahan pada data yang diambil dari sensor yang mengukur Suhu, Kelembaban, pH, dan Nutrisi dalam jangka waktu tertentu, serta mengidentifikasi titik-titik yang dianggap sebagai anomali menggunakan algoritma Isolation Forest.

Warna dan Simbol:

● : Mewakili nilai yang berada dalam rentang normal dari sensor.

● : Menunjukkan data yang telah diidentifikasi sebagai anomali.

Rincian Setiap Grafik:

- Suhu vs Waktu

Pola pengukuran suhu menunjukkan variasi yang signifikan, meskipun sebagian besar nilai berada dalam batas normal. Titik-titik anomali terdeteksi ketika terjadi lonjakan atau penurunan suhu yang tiba-tiba, yang dapat mengindikasikan adanya masalah pada sistem yang berfungsi.

- Kelembaban vs Waktu

Pola kelembaban menunjukkan fluktuasi yang cenderung mengikuti siklus tertentu, ditandai dengan beberapa puncak dan nilai rendah yang ekstrim. Anomali teridentifikasi ketika angka kelembaban menyimpang dari pola umum yang ada, berpotensi menunjukkan adanya gangguan dalam kontrol kelembaban sistem.

- pH vs Waktu

Variasi dari sensor pH tidak jauh berbeda dibandingkan dengan suhu atau kelembaban, meskipun nilai pH tertentu tetap muncul sebagai outlier. Titik anomali sering kali terjadi pada nilai pH yang sangat tinggi atau rendah, yang dapat berpengaruh terhadap kondisi tanaman.

- Nutrisi vs Waktu

Data dari sensor nutrisi menunjukkan variasi nilai yang cukup luas, termasuk puncak yang sangat tinggi dan rendah. Algoritma Isolation Forest mampu mendeteksi titik-titik anomali yang mencerminkan ketidakseimbangan dalam penyediaan nutrisi

Visualisasi ini memiliki peran penting dalam pemantauan sistem aeroponik secara real-time. Kemampuan untuk mendeteksi anomali dengan cepat melalui perubahan ekstrem mempermudah identifikasi masalah secara efisien, yang sangat bermanfaat untuk pemeliharaan preventif dan pengendalian kualitas dalam sistem pertanian berbasis Internet of Things (IoT).


4.3 Integrasi Model Deteksi Anomali ke dalam Sistem Web Monitoring

Setelah model Isolation Forest dilatih dan dievaluasi, tahap selanjutnya adalah mengintegrasikan model ke dalam sistem web untuk memungkinkan pengguna melakukan pemantauan secara real-time. Dalam sistem ini, FastAPI digunakan untuk memproses data dan mendeteksi anomali, sementara Streamlit digunakan untuk menampilkan hasil deteksi kepada pengguna dalam antarmuka web yang interaktif.

4.3.1. Arsitektur Sistem


Arsitektur sistem ini terdiri dari dua komponen utama:

1. FastAPI bertanggung jawab untuk:
 - Mengelola pengolahan data sensor.
 - Menerima dan memproses data dari sistem IoT.
 - Menjalankan model isolation forest untuk mendeteksi anomali pada data yang diterima.
 - Mengirimkan hasil deteksi anomali kepada **Streamlit** dalam format JSON.
2. Streamlit bertugas untuk:
 - Menerima hasil dari FastAPI melalui API.
 - Menampilkan data sensor dan hasil deteksi anomali kepada pengguna dalam bentuk visualisasi yang mudah dipahami (grafik, tabel, dan indikator anomali).



Gambar 4. 12 alur deployment

4.3.2. Tampilan Antarmuka Pengguna



Gambar 4. 13 interface user

Antarmuka pengguna yang dirancang dengan Streamlit menyajikan grafik temporal untuk setiap parameter sensor, termasuk suhu, kelembaban, pH, dan konsentrasi nutrisi, serta mencakup tanda-tanda anomali yang teridentifikasi. Dalam ilustrasi berikut, tampak bahwa grafik menunjukkan titik-titik merah yang menandakan anomali pada sejumlah parameter yang diukur.

- Anomali suhu diindikasikan dengan titik merah dalam grafik suhu.
- Parameter kelembaban, pH, dan konsentrasi nutrisi juga mencerminkan titik merah yang menandakan kehadiran anomali.

Dengan penerapan FastAPI dalam proses deteksi anomali dan Streamlit untuk mempresentasikan hasil kepada pengguna, sistem ini menyediakan kemampuan pemantauan terhadap kondisi lingkungan dalam sistem aeroponik pintar secara langsung. Metode deteksi anomali yang diadopsi melalui model Isolation Forest berfungsi untuk mengidentifikasi variasi yang mencurigakan dalam parameter lingkungan; hal ini memungkinkan tindakan intervensi yang lebih responsif dan pemeliharaan yang lebih efektif dalam pengelolaan sistem aeroponik.

Dalam bab ini, telah dilakukan penelaahan yang mendalam mengenai penggunaan model Isolation Forest untuk mendeteksi anomali dalam sistem aeroponik pintar yang berbasis sensor IoT. Fokus utama dari analisis ini adalah untuk mengenali berbagai tipe anomali dalam parameter lingkungan, termasuk suhu, kelembaban, pH, dan konsentrasi nutrisi, serta mengembangkan sebuah sistem deteksi anomali yang dapat diterapkan dalam konteks tersebut. Temuan dari penelitian ini menunjukkan bahwa model yang digunakan mampu mendeteksi anomali dengan tingkat ketepatan yang cukup tinggi pada data normal; meskipun demikian, tingkat pengingat (recall) yang diperoleh untuk anomali tergolong rendah. Ini mengindikasikan bahwa meskipun banyak anomali berhasil terdeteksi, masih terdapat kebutuhan untuk memperbaiki kemampuan model dalam mengenali anomali yang lebih jarang terjadi. Evaluasi yang dilakukan dengan menggunakan metrik f1-score dan silhouette score memberikan pemahaman yang baik tentang keseimbangan model dalam mendeteksi anomali serta pemisahan antara data normal dan anomali.

Selanjutnya, sistem yang terintegrasi dengan FastAPI untuk pemrosesan data dan Streamlit untuk menampilkan hasil deteksi secara real-time telah berhasil dijalankan, memungkinkan pemantauan kondisi

lingkungan dalam sistem aeroponik dengan pembaruan otomatis setiap tiga detik. Upaya ini bertujuan untuk meningkatkan efisiensi dan keandalan dalam pemantauan, dan sistem ini telah menunjukkan dampak signifikan dalam pengawasan sistem aeroponik, meskipun masih terdapat potensi untuk perbaikan, terutama dalam konteks peningkatan recall untuk deteksi anomali. Secara keseluruhan, hasil penelitian ini memenuhi tujuan yang telah ditetapkan, yakni mengidentifikasi anomali dalam data sensor IoT dan mengembangkan sebuah prototipe sistem deteksi anomali berbasis model Isolation Forest yang dapat diaplikasikan untuk memperbaiki ketepatan pemantauan dalam sistem aeroponik.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis yang telah dilakukan, disimpulkan bahwa penelitian ini berhasil mencapai target yang telah ditentukan, yaitu pengidentifikasian anomali pada parameter lingkungan sistem aeroponik yang didasarkan pada teknologi sensor IoT, evaluasi efektivitas algoritma Isolation Forest, serta penciptaan prototipe sistem deteksi anomali. Berikut adalah ringkasan utama dari hasil penelitian ini:

1. Pengidentifikasian Anomali pada Parameter Lingkungan Penelitian ini berhasil melakukan pengidentifikasian anomali pada sejumlah parameter lingkungan, di antaranya suhu, kelembaban, pH, dan konsentrasi nutrisi. Beberapa nilai anomali yang ditemukan meliputi suhu yang melebihi ambang batas normal ($42,5^{\circ}\text{C}$ dan $43,1^{\circ}\text{C}$), kelembaban yang sangat tinggi (94,9%), serta konsentrasi nutrisi yang tidak lazim (721,4 dan 240,9). Temuan ini menandakan adanya ketidakseimbangan dalam sistem yang dapat berdampak pada stabilitas pertumbuhan tanaman.
2. Kinerja Algoritma Isolation Forest Algoritma Isolation Forest terbukti efektif dalam mendeteksi anomali, meskipun terdapat beberapa keterbatasan. Tingkat presisi untuk deteksi data normal mencapai 61% dan untuk anomali 76%. Tingkat recall untuk data normal mencapai 85%, sementara untuk anomali hanya 46%, yang menunjukkan bahwa model ini masih memerlukan perbaikan, terutama dalam aspek peningkatan deteksi untuk anomali yang lebih jarang terjadi. Skor F1 untuk anomali adalah 0,57, sedangkan untuk data normal mencapai 0,71, mencerminkan adanya keseimbangan yang baik meskipun terdapat ruang untuk perbaikan lebih lanjut.
3. Prototipe Sistem Deteksi Anomali Prototipe sistem deteksi anomali berbasis web yang dikembangkan menggunakan FastAPI dan Streamlit telah berhasil diimplementasikan untuk memantau kondisi lingkungan dalam

sistem aeroponik secara real-time. Sistem ini melakukan pembaruan data setiap tiga detik, sehingga meningkatkan efisiensi dalam pemeliharaan dan menyediakan kemudahan bagi pengguna untuk memantau kondisi tanaman secara langsung.

5.2 Saran

Untuk meningkatkan kinerja dan keandalan sistem deteksi anomali ini, beberapa saran berikut dapat dipertimbangkan:

- 1) Peningkatan recall untuk deteksi anomali dengan melakukan optimasi lebih lanjut pada model. Salah satu pendekatan yang dapat digunakan adalah menyesuaikan parameter model seperti `contamination` dan `n\_estimators`.
- 2) Menambah variasi data sensor dalam pelatihan model, seperti data dari berbagai kondisi yang lebih ekstrem pada parameter suhu, kelembaban, pH, dan konsentrasi nutrisi, untuk melatih model agar dapat lebih memahami pola data yang kompleks dan meningkatkan akurasi deteksi anomali.
- 3) Mengintegrasikan fitur-fitur tambahan pada sistem monitoring untuk meningkatkan pengalaman pengguna, seperti:
 - Push Notification atau Peringatan Otomatis ketika anomali terdeteksi.
 - Fitur Auto-Tuning untuk Model agar dapat menyesuaikan dengan kondisi data yang berubah seiring waktu.
- 4) Meningkatkan sistem otomatisasi pemeliharaan dengan mengintegrasikan model deteksi anomali ke dalam sistem pengaturan suhu, kelembaban, dan nutrisi, sehingga tindakan perbaikan dapat dilakukan secara otomatis ketika terdeteksi anomali pada parameter lingkungan.

Dengan penerapan saran-saran tersebut, diharapkan model deteksi anomali dapat lebih optimal dan efektif dalam mendeteksi masalah pada sistem aeroponik pintar, sehingga pemantauan dan pemeliharaan sistem dapat dilakukan secara lebih efisien dan tepat waktu.

DAFTAR PUSTAKA

- Abdallah, M., Joung, B.-G., Lee, W. J., Mousoulis, C., Raghunathan, N., Shakouri, A., Sutherland, J. W., & Bagchi, S. (2023). Anomaly Detection and Inter-Sensor Transfer Learning on Smart Manufacturing Datasets. *Sensors*. <https://doi.org/10.3390/s23010486>
- Agarap, A. F. (2018b). *A Neural Network Architecture Combining Gated Recurrent Unit (GRU) and Support Vector Machine (SVM) for Intrusion Detection in Network Traffic Data*. <https://doi.org/10.1145/3195106.3195117>
- Airlangga, G. (2023a). Unsupervised Machine Learning for Seismic Anomaly Detection: Isolation Forest Algorithm Application to Indonesian Earthquake Data. *Jurnal Lebesgue Jurnal Ilmiah Pendidikan Matematika Matematika Dan Statistika*. <https://doi.org/10.46306/lb.v4i3.479>
- Akçay, S., Atapour-Abarghouei, A., & Breckon, T. P. (2019a). *GANomaly: Semi-Supervised Anomaly Detection via Adversarial Training*. https://doi.org/10.1007/978-3-030-20893-6_39
- Al Husaini, M., Zulianto, A., & Sasongko, D. A. (t.t.). *Otomatisasi Monitoring Metode Budidaya Sistem Hidroponik dengan Internet of Things (IoT) Berbasis Android MQTT dan Tenaga Surya*. <http://sostech.greenvest.co.id>
- Aliakbary, S., Motallebi, S., Rashidian, S., Habibi, J., & Movaghar, A. (2015a). Distance Metric Learning for Complex Networks: Towards Size-Independent Comparison of Network Structures. *Chaos an Interdisciplinary Journal of Nonlinear Science*. <https://doi.org/10.1063/1.4908605>
- Alsaedi, A., Moustafa, N., Tari, Z., Mahmood, A. N., & Anwar, A. (2020a). TON_IoT Telemetry Dataset: A New Generation Dataset of IoT and IIoT for Data-Driven Intrusion Detection Systems. *Ieee Access*. <https://doi.org/10.1109/access.2020.3022862>
- An, C., Park, Y. W., Ahn, S. S., Han, K., Kim, H., & Lee, S. K. (2021a). Radiomics Machine Learning Study With a Small Sample Size: Single Random Training-Test Set Split May Lead to Unreliable Results. *Plos One*. <https://doi.org/10.1371/journal.pone.0256152>
- Andika, F., Rizkinia, M., & Okuda, M. (2020). A Hyperspectral Anomaly Detection Algorithm Based on Morphological Profile and Attribute Filter With Band Selection and Automatic Determination of Maximum Area. *Remote Sensing*. <https://doi.org/10.3390/rs12203387>
- Anomaly Detection in Smart Grid Application. (2024a). *Interantional Journal of Scientific Research in Engineering and Management*. <https://doi.org/10.55041/ijsrem33546>

- Antonini, M., Pincheira, M., Vecchio, M., & Antonelli, F. (2023a). An Adaptable and Unsupervised TinyML Anomaly Detection System for Extreme Industrial Environments. *Sensors*. <https://doi.org/10.3390/s23042344>
- Arasy, R. C., Hannats, M., Ichsan, H., & Fitriyah, H. (2023). *Sistem Kendali Parameter Suhu dan Nutrisi Tanaman Bawang Putih pada Aeroponik menggunakan Metode Artificial Neural Network berbasis Arduino Uno* (Vol. 7, Nomor 7). <http://j-ptiik.ub.ac.id>
- Behniafar, M. (2023a). Anomaly Detection Fog (ADF): A Federated Approach for Internet of Things. *Scientia Iranica*. <https://doi.org/10.24200/sci.2022.57774.5410>
- Bobowicz, M. (2023). Attention-Based Deep Learning System for Classification of Breast Lesions—Multimodal, Weakly Supervised Approach. *Cancers*. <https://doi.org/10.3390/cancers15102704>
- Chatterjee, A. K., & Ahmed, B. S. (2022a). IoT Anomaly Detection Methods and Applications: A Survey. *Internet of Things*. <https://doi.org/10.1016/j.iot.2022.100568>
- Decoux, A., Duron, L., Habert, P., Roblot, V., Arsovic, E., Chassagnon, G., Arnoux, A., & Fournier, L. (2023a). *Comparative Performances of Machine Learning Algorithms in Radiomics and Impacting Factors*. <https://doi.org/10.21203/rs.3.rs-2677455/v1>
- Denanta, P., Perteka, B., Piarsa, N., & Wibawa, K. S. (t.t.). *Sistem Kontrol dan Monitoring Tanaman Hidroponik Aeroponik Berbasis Internet of Things*.
- DETEKSI ANOMALI MENGGUNAKAN ISOLATION FOREST BELANJA BARANG PERSEDIAAN KONSUMSI PADA SATUAN KERJA KEPOLISIAN REPUBLIK INDONESIA. (2023). *Jurnal Manajemen Perbendaharaan*, 4(1), 1–15. <https://doi.org/10.33105/jmp.v4i1.435>
- Ghosh, S. S., Dhar, R., Marcus, D. S., & Sotiras, A. (2023a). *Siam-Vae: A Hybrid Deep Learning Based Anomaly Detection Framework for Automated Quality Control of Head CT Scans*. <https://doi.org/10.1117/12.2654464>
- Han, X., Chen, X., & Liu, L. (2020a). *GAN Ensemble for Anomaly Detection*. <https://doi.org/10.48550/arxiv.2012.07988>
- Hariharan, A., Gupta, A., & Pal, T. (2020a). *CAMLPAD: Cybersecurity Autonomous Machine Learning Platform for Anomaly Detection*. https://doi.org/10.1007/978-3-030-39442-4_52
- Hariri, S., Kind, M. C., & Brunner, R. (2021a). Extended Isolation Forest. *Ieee Transactions on Knowledge and Data Engineering*. <https://doi.org/10.1109/tkde.2019.2947676>

- Hasan, M., Islam, Md. M., Islam Zarif, M. I., & A. Hashem, M. M. (2019a). Attack and Anomaly Detection in IoT Sensors in IoT Sites Using Machine Learning Approaches. *Internet of Things*. <https://doi.org/10.1016/j.iot.2019.100059>
- Kim, G.-I. (2023a). PatchCore-based Anomaly Detection Using Major Object Segmentation. *International Journal on Advanced Science Engineering and Information Technology*. <https://doi.org/10.18517/ijaseit.13.4.19020>
- Kim, G.-Y., Lim, S.-M., & Euom, I.-C. (2022). A Study on Performance Metrics for Anomaly Detection Based on Industrial Control System Operation Data. *Electronics*. <https://doi.org/10.3390/electronics11081213>
- Kim, J., Shin, Y., & Choi, E. (2019a). An Intrusion Detection Model Based on a Convolutional Neural Network. *Journal of Multimedia Information System*. <https://doi.org/10.33851/jmis.2019.6.4.165>
- Krishna Utama, I. B., Pamungkas, R. F., Faridh, M. M., & Jang, Y. M. (2023a). Intelligent IoT Platform for Multiple PV Plant Monitoring. *Sensors*. <https://doi.org/10.3390/s23156674>
- Lea, C., Flynn, M. D., Vidal, R., Reiter, A., & Hager, G. D. (2017a). *Temporal Convolutional Networks for Action Segmentation and Detection*. <https://doi.org/10.1109/cvpr.2017.113>
- Lesouple, J., Baudoin, C., Spigai, M., & Tourneret, J.-Y. (2021a). Generalized Isolation Forest for Anomaly Detection. *Pattern Recognition Letters*. <https://doi.org/10.1016/j.patrec.2021.05.022>
- Li, Y., Wei, X., Li, Y., Dong, Z., & Shahidehpour, M. (2022a). *Detection of False Data Injection Attacks in Smart Grid: A Secure Federated Deep Learning Approach*. <https://doi.org/10.1109/TSG.2022.3204796>
- Lima, A. L., Ferreira Rezende, S. W., Rabelo, D. S., Schroden Nomelini, Q. S., Silva, J. W., Finzi Neto, R. M., Gallo, C. A., & Reis Moura, J. dos. (2022a). Anomaly Detection Applied to ISHM for Thickness Reduction Analysis in Controlled Environments. *International Journal of Advanced Engineering Research and Science*. <https://doi.org/10.22161/ijaers.912.46>
- Meroni, M., Fasbender, D., Rembold, F., Atzberger, C., & Klisch, A. (2019b). Near Real-Time Vegetation Anomaly Detection With MODIS NDVI: Timeliness vs. Accuracy and Effect of Anomaly Computation Options. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2018.11.041>
- Munawarah, S., & Arip Winanto, E. (2024). *Jurnal Informatika Dan Rekayasa Komputer (JAKAKOM) Deteksi Serangan DDoS SYN Flood Pada Jaringan Internet of Things (IoT) Menggunakan Metode Deep Neural Network (DNN)*. 4(1). <https://doi.org/10.33998/jakakom.v4i1>


- Nassif, A. B., Talib, M. A., Nasir, Q., & Dakalbab, F. (2021a). Machine Learning for Anomaly Detection: A Systematic Review. *Ieee Access*. <https://doi.org/10.1109/access.2021.3083060>
- Ng, A. K., & Mahkeswaran, R. (2021a). Emerging and Disruptive Technologies for Urban Farming: A Review and Assessment. Dalam *Journal of Physics: Conference Series* (Vol. 2003, Nomor 1). IOP Publishing Ltd. <https://doi.org/10.1088/1742-6596/2003/1/012008>
- Ngo, M. V, Luo, T., Chaouchi, H., & S. Quek, T. Q. (2020a). *Contextual-Bandit Anomaly Detection for IoT Data in Distributed Hierarchical Edge Computing*. <https://doi.org/10.1109/icdcs47774.2020.00191>
- Nguyen, V. H., Nguyen, T. T., & Nguyen, U. (2017a). An Evaluation Method for Unsupervised Anomaly Detection Algorithms. *Journal of Computer Science and Cybernetics*. <https://doi.org/10.15625/1813-9663/32/3/8455>
- Nugroho, A., Husin, A., Provinsi, J., Hulu, T., & Hilir Indonesia, I. (t.t.). SISTEMASI: Jurnal Sistem Informasi Analisis Performa Random Forest Menggunakan Normalisasi Atribut Performance Analysis of Random Forest Using Attribute Normalization. Dalam *Januari* (Vol. 11, Nomor 1). <http://sistemasi.ftik.unisi.ac.id>
- Nusrat, A. (2023a). Machine Learning Techniques for Detecting Anomalies in IoT Networks. *International Journal of Computer Engineering in Research Trends*. <https://doi.org/10.22362/ijcert/2023/v10/i10/v10i103>
- Okey, O. D., Maidin, S. S., Adasme, P., Rosa, R. L., Saadi, M., Carrillo, D., & Rodríguez, D. Z. (2022a). BoostedEnML: Efficient Technique for Detecting Cyberattacks in IoT Systems Using Boosted Ensemble Machine Learning. *Sensors*. <https://doi.org/10.3390/s22197409>
- Olateju, O. O. (2024a). Combating the Challenges of False Positives in AI-Driven Anomaly Detection Systems and Enhancing Data Security in the Cloud. *Asian Journal of Research in Computer Science*. <https://doi.org/10.9734/ajrcos/2024/v17i6472>
- Pathak, A., Saguna, S., Mitra, K., & Åhlund, C. (2021a). *Anomaly Detection Using Machine Learning to Discover Sensor Tampering in IoT Systems*. <https://doi.org/10.1109/icc42927.2021.9500825>
- Pathak, A., Saguna, S., Mitra, K., & Åhlund, C. (2021b). *Anomaly Detection Using Machine Learning to Discover Sensor Tampering in IoT Systems*. <https://doi.org/10.1109/icc42927.2021.9500825>
- Prawiranegara, B. M. P., Sugandi, W. K., Akbar, R. J., & Situmorang, Y. L. A. (2023). Aeroponic Plant House System Using Direct Seeding in the Seedling

- Phase to Improve the Growth and Quality of Kangkung (*Ipomoea aquatica* Forssk.). *Jurnal Keteknikan Pertanian*, 11(3), 307–317. <https://doi.org/10.19028/jtep.011.3.307-317>
- Punta Dewa, R. (t.t.). *Network Anomaly Detection Using Isolation Forest on Wazuh Logs with WhatsApp Notifications at PT XYZ*. <https://jurnaldrpm.budiluhur.ac.id/index.php/Kresna/>
- Rifa', A., Udin, M., Al Rasyid, H., Gunawan, A. I., Elektronika, P., & Surabaya, N. (2021). SISTEM PEMANTAUAN DAN KONTROL OTOMATIS KUALITAS AIR BERBASIS IOT MENGGUNAKAN PLATFORM NODE-RED UNTUK BUDIDAYA UDANG 1. *Jurnal Teknologi Terapan* |, 7(1).
- Riyanto, S., Sitanggang, I. S., Djatna, T., & Atikah, T. D. (2023). Comparative Analysis Using Various Performance Metrics in Imbalanced Data for Multi-Class Text Classification. *International Journal of Advanced Computer Science and Applications*. <https://doi.org/10.14569/ijacsa.2023.01406116>
- Shao, L., Zhang, X., Teng, H., Chen, Y., Zhang, C., Dong, L., Ling, S., Zhang, D., Zhou, W., Zhang, R. H., Qin, L., & Wei, W. Bin. (2022). Prediction of the Fundus Tessellation Severity With Machine Learning Methods. *Frontiers in Medicine*. <https://doi.org/10.3389/fmed.2022.817114>
- Sunarto, M. W., Kurniawan, D., Siswanto, E., & Huda, H. I. (2021). *Deteksi Anomali Menggunakan Extended Isolation Forest (Eif)*. 1(2), 96–111. <http://journal.stiestekom.ac.id/index.php/TEKNIK□page111>
- Tamba, P. (2022). PREDIKSI PENYAKIT GAGAL JANTUNG DENGAN MENGGUNAKAN RANDOM FOREST. *Jurnal Sistem Informasi dan Ilmu Komputer Prima*, 5(2).
- Togbe, M. U., Barry, M., Boly, A., Chabchoub, Y., Chiky, R., Montiel, J., & Tran, V.-T. (2020c). *Anomaly Detection for Data Streams Based on Isolation Forest Using Scikit-Multiflow*. https://doi.org/10.1007/978-3-030-58811-3_2
- Togbe, M. U., Chabchoub, Y., Boly, A., Barry, M., Chiky, R., & Bahri, M. (2021a). Anomalies Detection Using Isolation in Concept-Drifting Data Streams. *Computers*. <https://doi.org/10.3390/computers10010013>
- Ullah, W., Ullah, A., Hussain, T., Khan, Z. A., & Baik, S. W. (2021). An Efficient Anomaly Recognition Framework Using an Attention Residual LSTM in Surveillance Videos. *Sensors*. <https://doi.org/10.3390/s21082811>
- Vabalas, A., Gowen, E., Poliakoff, E., & Casson, A. J. (2019b). Machine Learning Algorithm Validation With a Limited Sample Size. *Plos One*. <https://doi.org/10.1371/journal.pone.0224365>

- Velásquez, D., Pérez, E. G., Oregui, X., Artetxe, A., Manteca, J., Mansilla, J. E., Toro, M., Maiza, M., & Sierra, B. (2022a). A Hybrid Machine-Learning Ensemble for Anomaly Detection in Real-Time Industry 4.0 Systems. *Ieee Access*. <https://doi.org/10.1109/access.2022.3188102>
- Wang, C., Viswanathan, K., Lakshminarayan, C., Talwar, V., Satterfield, W., & Schwan, K. (2011a). *Statistical Techniques for Online Anomaly Detection in Data Centers*. <https://doi.org/10.1109/inm.2011.5990537>
- Wang, Y., Sun, G., Cao, X., & Yang, J. (2022b). An Intrusion Detection System for the Internet of Things Based on the Ensemble of Unsupervised Techniques. *Wireless Communications and Mobile Computing*. <https://doi.org/10.1155/2022/8614903>
- Wina Sumiar, N. (t.t.). *Pengembangan Sistem Pengaturan Larutan Nutrisi Otomatis Pada Budidaya Kentang Aeroponik Development of Automatic Nutrient Solution Regulatory System in Aeroponic Potato Cultivation*. <http://journal.ipb.ac.id/index>.
- Yazid, I., Octo Ingetenta, S., Yusro3), M., Iii, D., & Elektronika, T. (t.t.). *Prototipe Pengamatan Budidaya Aeroponik berbasis IoT (Internet of Things)*.
- Zakariah, M. (2023a). Anomaly Detection for IOT Systems Using Active Learning. *Applied Sciences*. <https://doi.org/10.3390/app132112029>
- Zoppi, T., Ceccarelli, A., & Bondavalli, A. (2019a). *Evaluation of Anomaly Detection Algorithms Made Easy With RELOAD*. <https://doi.org/10.1109/issre.2019.00051>
- Vasiljević, J., Gligorić, N., & Devedžić, V. (2025). Federated Isolation Forest for IoT Edge Devices. *arXiv preprint arXiv:2506.05138*. <https://arxiv.org/abs/2506.05138>
- Chen, C., Ma, X., Liu, W., Zhu, Y., & Zhai, J. (2023). BS-iForest: An Improved Isolation Forest for Anomaly Detection in Wireless Sensor Networks. *Applied Sciences*, 13(2), 702. <https://doi.org/10.3390/app13020702>
- Moso, R., Yalou, M., Zgorski, M., Ruan, X., & Velasco, G. (2021). Anomaly Detection in Multispectral SAR Data Streams for Smart Agriculture Using Isolation Forest. *Agriculture*, 11(11), 1083. <https://doi.org/10.3390/agriculture11111083>

LAMPIRAN

proses pengambilan data



Sourcode pembuatan machine learning

```
# Import Library yang dibutuhkan
import joblib
import pandas as pd
from sklearn.ensemble import IsolationForest
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split
from imblearn.over_sampling import SMOTE # Import SMOTE
import matplotlib.pyplot as plt
import numpy as np
from keras.models import Model
from keras.layers import Input, Dense

# Membaca dataset
df = pd.read_csv('file_output_terbaru_dengan_timestamp.csv')

# Menghapus kolom timestamp
sensor_value = df.drop(columns=['timestamp'])

# Menampilkan 5 baris pertama dan terakhir dari dataset
print("=== Data Awal ===")
print(df.head())

print("=== Data Akhir ===")
print(df.tail())

# Menghapus baris yang memiliki missing value
df_cleaned = df.dropna()

# Tampilkan data setelah pembersihan
```

```

print("=== Data Setelah Menghapus Missing Values ===")
print(df_cleaned.head())

# Normalisasi data
scaler = MinMaxScaler()
scaled_data = scaler.fit_transform(sensor_value)

# Tampilkan data yang sudah dinormalisasi
scaled_df = pd.DataFrame(scaled_data, columns=sensor_value.columns)
print("=== Data Setelah Normalisasi ===")
print(scaled_df.head())

# Simpan hasil normalisasi ke file CSV (optional)
scaled_df.to_csv('scaled_sensor_value_terbaru.csv', index=False)
print("Hasil normalisasi disimpan di 'scaled_sensor_value_terbaru.csv'")

# Langkah 1: Membagi data menjadi data pelatihan dan pengujian
X_train, X_test = train_test_split(scaled_data, test_size=0.2, random_state=42)

print(f"Ukuran data pelatihan: {X_train.shape}")
print(f"Ukuran data pengujian: {X_test.shape}")

# Langkah 2: Latih Autoencoder untuk Mendeteksi Anomali
input_dim = X_train.shape[1] # Dimensi data
encoding_dim = 32 # Ukuran encoding (lebih kecil)

# Definisikan arsitektur Autoencoder
input_layer = Input(shape=(input_dim,))
encoded = Dense(encoding_dim, activation='relu')(input_layer)
decoded = Dense(input_dim, activation='sigmoid')(encoded)

autoencoder = Model(input_layer, decoded)

```

```

autoencoder.compile(optimizer='adam', loss='mean_squared_error')

# Latih Autoencoder dengan epoch 1000
autoencoder.fit(X_train, X_train, epochs=1000, batch_size=256,
shuffle=True, initial_epoch=721)

# Menyimpan model Autoencoder setelah pelatihan selesai
autoencoder.save('autoencoder_model.h5')
print("Model Autoencoder disimpan di 'autoencoder_model.h5'")

# -----
# Hitung Rekonstruksi Error pada Data Pelatihan
# -----
# Prediksi data dengan Autoencoder (hasil rekonstruksi)
reconstructed_data_train = autoencoder.predict(X_train)
reconstruction_error_train = np.mean(np.abs(X_train -
reconstructed_data_train), axis=1)

# Tampilkan distribusi rekonstruksi error untuk data pelatihan
plt.figure(figsize=(10, 6))
plt.hist(reconstruction_error_train, bins=50, color='skyblue', edgecolor='black')
plt.title("Distribution of Reconstruction Error on Training Data")
plt.xlabel("Reconstruction Error")
plt.ylabel("Frequency")
plt.show()

# Langkah 3: Tentukan target label berdasarkan rekonstruksi error pada data
pelatihan
# Misalkan error yang lebih tinggi dari threshold dianggap sebagai anomali
threshold = np.percentile(reconstruction_error_train, 70) # Ambil nilai error
yang lebih besar dari persentil ke-95 sebagai anomali

```

```

y_train = (reconstruction_error_train > threshold).astype(int) # 1 = Anomali, 0
= Normal

print(f"Threshold untuk deteksi anomali: {threshold}")
print(f"Jumlah data anomali (label 1): {np.sum(y_train == 1)}")
print(f"Jumlah data normal (label 0): {np.sum(y_train == 0)}")
# Langkah 4: Terapkan SMOTE untuk Oversampling pada Data Pelatihan
smote = SMOTE(random_state=100)
X_train_oversampled, y_train_oversampled = smote.fit_resample(X_train,
y_train) # Resampling data pelatihan

print(f"Ukuran data pelatihan setelah oversampling:
{X_train_oversampled.shape}")
# Langkah 5: Gunakan Isolation Forest pada Rekonstruksi Error dari Data
Pelatihan
iso_forest = IsolationForest(contamination=0.3) # Misal 20% data dianggap
anomali
iso_forest.fit(reconstruction_error_train.reshape(-1, 1))

# Prediksi anomali pada data pengujian
reconstructed_data_test = autoencoder.predict(X_test)
reconstruction_error_test = np.mean(np.abs(X_test - reconstructed_data_test),
axis=1)

# Prediksi anomali pada data pengujian
anomalies_test = iso_forest.predict(reconstruction_error_test.reshape(-1, 1))

# Anomali akan diberi label -1, normal diberi label 1
print("Anomalies detected on test data:", np.where(anomalies_test == -1)[0])
# Prediksi anomali pada data uji
y_pred = iso_forest.predict(X_test_fold)

```

```

y_pred = [1 if x == -1 else 0 for x in y_pred]

# Tampilkan jumlah anomali yang terdeteksi
print(f"Jumlah anomali yang terdeteksi: {np.sum(y_pred)}")

# Visualisasi atau evaluasi lain yang relevan
plt.hist(y_pred, bins=2, color='blue', edgecolor='black')
plt.title('Anomaly Detection Results')
plt.xlabel('Class')
plt.ylabel('Frequency')
plt.show()

from sklearn.model_selection import StratifiedKFold
from sklearn.metrics import (
    precision_score, recall_score, f1_score,
    confusion_matrix, ConfusionMatrixDisplay,
    classification_report
)
import numpy as np
import matplotlib.pyplot as plt
import joblib

# Simpan model dan scaler
joblib.dump(iso_forest, 'isolation_forest_model.pkl')
print("Model Isolation Forest disimpan di 'isolation_forest_model.pkl'")

joblib.dump(scaler, 'scaler.pkl')
print("Scaler disimpan di 'scaler.pkl'")

# Inisialisasi Stratified KFold
kf = StratifiedKFold(n_splits=10, shuffle=True, random_state=42)

```

```

# List untuk metrik evaluasi
precision_list, recall_list, f1_list = [], [], []
all_y_true = []
all_y_pred = []

# Cross-validation loop
for fold, (train_idx, test_idx) in enumerate(kf.split(X_train_oversampled,
y_train_oversampled), 1):
    X_train_fold = X_train_oversampled[train_idx]
    X_test_fold = X_train_oversampled[test_idx]
    y_train_fold = y_train_oversampled[train_idx]
    y_test_fold = y_train_oversampled[test_idx]

    # Fit model
    iso_forest.fit(X_train_fold)

    # Prediksi
    y_pred = iso_forest.predict(X_test_fold)
    y_pred = [1 if x == -1 else 0 for x in y_pred] # 1 = anomali

    # Evaluasi metrik
    precision = precision_score(y_test_fold, y_pred)
    recall = recall_score(y_test_fold, y_pred)
    f1 = f1_score(y_test_fold, y_pred)
    cm = confusion_matrix(y_test_fold, y_pred)

    print(f"\n=== Evaluasi Fold {fold} ===")
    print(f"Precision : {precision:.4f}")
    print(f"Recall   : {recall:.4f}")
    print(f"F1-Score  : {f1:.4f}")

```

```

print("Confusion Matrix:")
print(cm)

# Classification Report per fold (opsional)
print("Classification Report:")
print(classification_report(y_test_fold, y_pred, target_names=["Normal (0)",
"Anomali (1)"]))

# Visualisasi Confusion Matrix per fold
disp = ConfusionMatrixDisplay(confusion_matrix=cm,
display_labels=["Normal (0)", "Anomali (1)"])
disp.plot(cmap=plt.cm.Blues)
plt.title(f"Confusion Matrix Fold {fold}")
plt.tight_layout()
plt.show()

# Simpan semua metrik dan label
precision_list.append(precision)
recall_list.append(recall)
f1_list.append(f1)
all_y_true.extend(y_test_fold)
all_y_pred.extend(y_pred)

# Rata-rata metrik
print("\n=== Rata-rata Evaluasi 10-Fold ===")
print(f"Average Precision : {np.mean(precision_list):.4f}")
print(f"Average Recall   : {np.mean(recall_list):.4f}")
print(f"Average F1-Score  : {np.mean(f1_list):.4f}")

# Confusion Matrix Gabungan
cm_total = confusion_matrix(all_y_true, all_y_pred)

```

```

print("\n=== Confusion Matrix Gabungan ===")
print(cm_total)

# Visualisasi Confusion Matrix Gabungan
disp = ConfusionMatrixDisplay(confusion_matrix=cm_total,
display_labels=["Normal (0)", "Anomali (1)"])
disp.plot(cmap=plt.cm.Blues)
plt.title("Confusion Matrix Gabungan (10-Fold)")
plt.tight_layout()
plt.show()

# Classification Report Gabungan
print("\n=== Classification Report Gabungan ===")
print(classification_report(all_y_true, all_y_pred, target_names=["Normal (0)",
"Anomali (1)"]))

# Prediksi seluruh data untuk disimpan
df['is_anomaly'] = iso_forest.predict(scaled_data)
df['is_anomaly'] = df['is_anomaly'].map({1: False, -1: True})

# Simpan hasil deteksi
df.to_csv("hasil_training_anomali_final.csv", index=False)
anomaly_count = df['is_anomaly'].value_counts()[True]
normal_count = df['is_anomaly'].value_counts()[False]

print(f"\nJumlah anomaly: {anomaly_count}")
print(f"Jumlah normal : {normal_count}")

```

Sourcode fastAPI

```
from FastAPI import FastAPI, HTTPException
from pydantic import BaseModel
import joblib
import sqlite3
import pandas as pd
from datetime import datetime

# Inisialisasi aplikasi FastAPI
app = FastAPI(title="Smart Aeroponik API", version="1.0")

# Muat model dan scaler yang telah dilatih
MODEL_PATH = "src/api/model/isolation_forest_model.pkl"
SCALER_PATH = "src/api/model/scaler.pkl"
DB_PATH = "src/api/data.db"

try:
    model = joblib.load(MODEL_PATH)
    scaler = joblib.load(SCALER_PATH)
except Exception as e:
    raise RuntimeError(f"Gagal memuat model atau scaler: {e}")

# Skema data yang diterima dari client menggunakan Pydantic
class SensorData(BaseModel):
    suhu: float
    kelembaban: float
    ph: float
    nutrisi: float
```

```

@app.post("/predict", summary="Prediksi dan Simpan Data Sensor",
response_description="Hasil prediksi data sensor")
def predict(data: SensorData):
    """
    Endpoint untuk melakukan prediksi apakah data sensor termasuk anomali atau
    tidak,
    serta menyimpan hasil prediksi ke database SQLite.
    """
    try:
        # Ambil waktu saat ini dalam format ISO
        timestamp = datetime.now().isoformat()

        # Konversi data input menjadi DataFrame
        df_input = pd.DataFrame([data.model_dump()])

        # Normalisasi data
        scaled_input = scaler.transform(df_input)

        # Prediksi dengan model Isolation Forest
        prediction = model.predict(scaled_input)
        is_anomaly = False if prediction[0] == 1 else True

        # Simpan data dan hasil prediksi ke database SQLite
        with sqlite3.connect(DB_PATH) as conn:
            cursor = conn.cursor()
            cursor.execute(
                """
                INSERT INTO sensor_data (timestamp, suhu, kelembaban, ph, nutrisi,
is_anomaly)
                VALUES (?, ?, ?, ?, ?, ?)
                """,

```

```

        (
            timestamp,
            data.suhu,
            data.kelembaban,
            data.ph,
            data.nutrisi,
            is_anomaly,
        )
    )
    conn.commit()

# Kembalikan hasil prediksi ke client
return {
    "timestamp": timestamp,
    **data.model_dump(),
    "is_anomaly": bool(is_anomaly)
}

except Exception as e:
    raise HTTPException(status_code=500, detail=f"Gagal melakukan prediksi: {str(e)}")

```

Sourcode streamlit untuk user visual

```

import streamlit as st
import pandas as pd
import sqlite3
import altair as alt
from streamlit_autorefresh import st_autorefresh

```

```

# Konfigurasi halaman Streamlit
st.set_page_config(page_title="Monitoring Sensor", layout="wide")
st.title("🌱 Monitoring Data Sensor Smart Aeroponik")

# Informasi mengenai auto-refresh halaman
st.info("🔄 Halaman akan auto-refresh setiap 3 detik untuk menampilkan data terbaru.")
st.autorefresh(interval=3 * 1000, key="data_refresh")

# Membuka koneksi ke database SQLite
DB_PATH = "src/api/data.db"
conn = sqlite3.connect(DB_PATH)

# Membaca data terbaru dari tabel sensor_data
query = "SELECT * FROM sensor_data"
df = pd.read_sql_query(query, conn)

# Mengurutkan berdasarkan timestamp dan mengambil 30 data terakhir
df = df.sort_values(by="timestamp").tail(30)

# Daftar fitur sensor yang akan divisualisasikan
fitur_list = ["suhu", "kelembaban", "ph", "nutrisi"]

# Mengubah format data menjadi long-format agar bisa dipakai di Altair (visualisasi)
df_long = df.melt(
    id_vars=["timestamp", "is_anomaly"],
    value_vars=fitur_list,
    var_name="fitur",

```

```

        value_name="nilai",
    )

# Membuat chart garis untuk visualisasi data sensor
garis_chart = (
    alt.Chart(df_long)
    .mark_line()
    .encode(
        x="timestamp",
        y=alt.Y("nilai:Q", title="Nilai Sensor"),
        color="fitur:N",
        tooltip=["timestamp", "fitur:N", "nilai:Q"],
    )
)

# Filter data anomali untuk ditampilkan sebagai titik merah
anomali = df_long[df_long["is_anomaly"] == 1]
anomali_chart = (
    alt.Chart(anomali)
    .mark_circle(size=60, color="red")
    .encode(
        x="timestamp",
        y="nilai:Q",
        tooltip=["timestamp", "fitur:N", "nilai:Q"]
    )
)

# Gabungkan grafik garis dan titik anomali
chart = (
    (garis_chart + anomali_chart)

```

```

.properties(title="📊 Sensor vs Waktu + Anomali")
.interactive()
)

```

Tampilkan chart di halaman Streamlit

```
st.altair_chart(chart, use_container_width=True)
```

Ujicoba web

