



Sistem Prediksi dan Deteksi Anomali Berbasis Iot-Time Series Dengan Pendekatan Explainable AI

Bonitalia¹, Eric Alfonsius^{2*}

¹*Teknik Informatika, STMIK Adhi Guna,*

Jl. Undata No. 3, Palu 94111, Indonesia

²*Sistem Informasi, Universitas Sam Ratulangi,*

Jl. Kampus, Manado 95115, Indonesia

*Email Penulis Koresponden: ericalfonsius@unsrat.ac.id

Abstrak:

Budidaya anggur memerlukan pemantauan intensif terhadap kondisi lingkungan seperti kelembaban tanah, pH, dan kadar nutrisi untuk memastikan pertumbuhan optimal dan kualitas panen yang tinggi. Penelitian ini mengusulkan pengembangan sistem prediksi dan deteksi anomali berbasis Internet of Things (IoT) dan analisis deret waktu (time series) yang dilengkapi dengan pendekatan Explainable Artificial Intelligence (XAI). Sistem ini mengintegrasikan sensor IoT untuk pengumpulan data real-time dari lahan budidaya anggur, kemudian menerapkan model prediksi berbasis machine learning untuk memantau pola perubahan parameter lingkungan. Deteksi anomali dilakukan menggunakan metode unsupervised learning yang mampu mengidentifikasi penyimpangan dari kondisi normal, sehingga memberikan peringatan dini kepada petani. Komponen XAI digunakan untuk menjelaskan alasan di balik setiap deteksi anomali, sehingga meningkatkan transparansi dan kepercayaan pengguna terhadap hasil sistem. Hasil pengujian menunjukkan bahwa sistem mampu mencapai tingkat akurasi prediksi sebesar 92% dan sensitivitas deteksi anomali sebesar 89%, sehingga efektif membantu dalam pengambilan keputusan terkait irigasi, pemupukan, dan tindakan korektif lainnya. Temuan ini diharapkan dapat mendukung praktik pertanian presisi dan meningkatkan produktivitas serta efisiensi dalam budidaya anggur.

This is an open access article under the [CC BY-NC](#) license



Kata Kunci:

Internet of Things (IoT);
Time Series;
Explainable Artificial Intelligence;
Deteksi Anomali;
Sistem Prediksi;

Riwayat Artikel:

Diserahkan 02 Oktober 2025

Direvisi 12 April 2026

Diterima 13 April 2026

DOI:

10.22441/incomtech.v16i2.36449

1. PENDAHULUAN

Budidaya anggur merupakan salah satu sektor agrikultur yang memiliki nilai ekonomi tinggi dan terus berkembang seiring meningkatnya permintaan pasar [1].

Kualitas hasil panen sangat dipengaruhi oleh stabilitas parameter lingkungan, seperti kelembaban tanah, pH, dan kadar nutrisi [2], [3]. Ketidakseimbangan dalam parameter tersebut dapat menyebabkan penurunan kualitas buah, menghambat pertumbuhan tanaman, bahkan menimbulkan kerugian finansial yang signifikan bagi petani [4], [5], [6]. Pemantauan secara manual sering kali memakan waktu [7], memerlukan tenaga kerja yang besar, dan rentan terhadap keterlambatan dalam pengambilan keputusan, sehingga upaya mitigasi menjadi kurang efektif.

Kemajuan teknologi Internet of Things (IoT) dan kecerdasan buatan (AI) memberikan peluang untuk menciptakan sistem monitoring [8], [9] dan prediksi yang mampu bekerja secara real-time dan otomatis [10], [11]. Namun, sebagian besar sistem cerdas yang ada masih berperan sebagai “kotak hitam” yang sulit dipahami pengguna, sehingga keputusan yang dihasilkan terkadang menimbulkan keraguan. Oleh karena itu, dibutuhkan sistem yang tidak hanya mampu memprediksi perubahan kondisi lingkungan tetapi juga memberikan penjelasan yang dapat dipahami mengenai alasan di balik deteksi anomali.

Penelitian terkait pemantauan budidaya anggur berbasis Internet of Things (IoT) telah banyak dilakukan, terutama pada aspek pengumpulan data real-time untuk parameter lingkungan seperti suhu, kelembapan udara, dan deteksi penyakit tanaman. Misalnya, sistem IoT untuk deteksi penyakit anggur berbasis jaringan sensor, yang mampu memantau kondisi lingkungan secara kontinu [12]. Namun, penelitian tersebut tidak memfokuskan pada kombinasi parameter kelembaban tanah, pH, dan nutrisi yang berperan penting terhadap kualitas hasil panen. Penelitian lain mengusulkan metode deteksi dan koreksi data anomali menggunakan kombinasi CNN-SVM dan LSTM untuk perkebunan [13], tetapi pendekatannya lebih menekankan pada koreksi data daripada memberikan prediksi jangka pendek maupun transparansi keputusan. Penelitian yang mengintegrasikan pemantauan parameter kelembaban tanah, pH, dan nutrisi secara simultan menggunakan IoT, analisis deret waktu untuk prediksi, deteksi anomali berbasis machine learning, serta penjelasan keputusan melalui XAI dalam satu kerangka sistem masih sangat terbatas. Oleh karena itu, penelitian ini berkontribusi dalam mengisi gap tersebut dengan mengembangkan sistem prediksi dan deteksi anomali yang tidak hanya memantau parameter lingkungan utama pada budidaya anggur, tetapi juga memanfaatkan analisis deret waktu untuk memproyeksikan kondisi masa depan, memberikan peringatan dini terhadap penyimpangan, dan menyertakan komponen XAI untuk meningkatkan transparansi serta kepercayaan pengguna. Pendekatan ini diharapkan dapat mendukung pengambilan keputusan yang lebih cepat, akurat, dan berbasis data, sehingga berkontribusi pada praktik pertanian presisi dan peningkatan produktivitas budidaya anggur.

Penelitian ini mengembangkan sebuah sistem prediksi dan deteksi anomali berbasis IoT [14] dan analisis deret waktu yang dipadukan dengan Explainable Artificial Intelligence (XAI). Sistem ini dirancang untuk membantu petani memantau parameter penting budidaya anggur secara berkelanjutan dan memberikan peringatan dini terhadap kondisi yang menyimpang. Dengan demikian, petani dapat mengambil keputusan secara cepat dan tepat, seperti mengatur irigasi, pemupukan, atau tindakan perbaikan lainnya.

Untuk mencapai tujuan tersebut, penelitian ini mengintegrasikan sensor IoT yang mengumpulkan data lapangan secara real-time dengan model prediksi berbasis machine learning. Data yang diperoleh dianalisis menggunakan metode

time series untuk mendeteksi pola perubahan, sementara modul deteksi anomali mengidentifikasi penyimpangan dari kondisi normal. Komponen XAI ditambahkan untuk meningkatkan transparansi sistem dan memudahkan pengguna memahami alasan di balik setiap keputusan yang dihasilkan.

2. METODE

Bagian ini menjelaskan pendekatan penelitian yang digunakan untuk mencapai tujuan yang telah dirumuskan pada pendahuluan. Metode penelitian dirancang secara sistematis agar mampu memprediksi parameter lingkungan [15] penting pada budidaya anggur, sekaligus mendeteksi adanya anomali secara real-time. Fokus utama adalah pada pengumpulan data sensor IoT, pengolahan data, perancangan model prediksi berbasis time series, menggunakan algoritma Long Short-Term Memory (LSTM) yang efektif dalam menangkap pola temporal jangka panjang.

Selain itu, mekanisme deteksi anomali dilakukan dengan menggunakan algoritma Isolation Forest, yang mampu mengidentifikasi data yang menyimpang secara efisien tanpa memerlukan label data (unsupervised). Untuk meningkatkan transparansi dan interpretabilitas model, penelitian ini juga mengintegrasikan pendekatan Explainable AI (XAI) guna memberikan penjelasan terhadap hasil prediksi dan deteksi anomali.

Pemilihan metode ini diharapkan dapat menghasilkan sistem yang tidak hanya akurat, tetapi juga transparan dan mudah diinterpretasikan oleh pengguna, sehingga mampu membantu petani dalam mengambil keputusan yang tepat terhadap kondisi kebun anggur.

2.1 Formulasi Permasalahan

Permasalahan utama dalam penelitian ini adalah mendeteksi anomali dan memprediksi perubahan parameter lingkungan budidaya anggur, yaitu kelembapan tanah (H_t), pH tanah (pH_t), dan suhu lingkungan (T_t) secara real-time. Ketiga parameter ini direpresentasikan sebagai vektor multivariat:

$$X_t = \{H_t, pH_t, T_t\} \quad t = 1, 2, \dots, T \quad (1)$$

2.2 Tujuan penelitian

1. Prediksi (Forecasting): Mencari fungsi $f(\cdot)$ yang dapat memprediksi nilai parameter pada waktu mendatang X_{t+k} berdasarkan data historis $X_{1:t}$:

$$X_{t+k} = f(X_t, X_{t-1}, \dots, X_{t-n}) \quad (2)$$

2. Deteksi Anomali: Menentukan apakah suatu observasi X_t merupakan anomali atau tidak dengan mendefinisikan skor anomali A_t :

$$A_t = g(X_t, \hat{X}_t), \text{ dengan anomaly jika } A_t > 0 \quad (3)$$

di mana $\hat{X}_t$ adalah nilai prediksi, $g(\cdot)$ adalah fungsi jarak/error (misalnya Mean Absolute Error atau Reconstruction Error), dan $\hat{o}$ adalah ambang batas adaptif.

2.3 Arsitektur Sistem

Sistem yang dikembangkan terdiri dari empat tahap utama:

1. Akuisisi Data: Sensor IoT mengukur kelembapan tanah, pH tanah, dan suhu lingkungan secara real-time. Data dikirim ke server menggunakan protokol komunikasi MQTT/HTTP.
2. Preprocessing: Data dilakukan pembersihan (filtering outliers, imputasi missing values) dan normalisasi:

$$X_t^l = \frac{X_t - \mu}{\sigma} \quad (4)$$

3. Model Prediksi Time Series: Menggunakan model LSTM (Long Short-Term Memory) karena kemampuannya menangkap dependensi jangka panjang. Fungsi prediksi $f(\cdot)$ dilatih dengan meminimalkan fungsi loss Mean Squared Error:

$$L_{pred} = \frac{1}{T} \sum_{t=1}^T || X_t - \hat{X}_t ||^2 \quad (5)$$

4. Deteksi Anomali dan XAI: Setelah nilai prediksi diperoleh, error dihitung dan dibandingkan dengan ambang θ . Jika error melebihi ambang, data ditandai sebagai anomali. Untuk meningkatkan transparansi, digunakan Explainable AI seperti SHAP (SHapley Additive exPlanations) atau LIME yang memberikan kontribusi masing-masing parameter terhadap hasil prediksi:

$$\theta_i = \text{SHAP}(X_t, f) \quad (6)$$

di mana θ menunjukkan kontribusi fitur i (kelembapan, pH, atau suhu) terhadap keputusan model.

2.4 Penelitian Terkait

Penelitian sebelumnya banyak menggunakan sensor IoT untuk pemantauan suhu dan kelembapan serta model prediksi berbasis Long Short-Term Memory (LSTM) atau Autoencoder. Wang dkk. (2023) menerapkan LSTM untuk deteksi data abnormal pada perkebunan teh, sedangkan Steinkellner (2024) menggunakan Autoencoder untuk mendeteksi anomali visual pada kebun anggur.

Selain itu, penelitian terbaru yang dipublikasikan pada IEEE (2024) menunjukkan bahwa kombinasi model berbasis LSTM dalam lingkungan Internet of Things (IoT) mampu meningkatkan akurasi deteksi anomali pada data time series dengan performa tinggi, terutama dalam menangani data multivariat dan pola temporal yang kompleks. Model berbasis LSTM terbukti efektif dalam menangkap dependensi jangka panjang serta meningkatkan nilai evaluasi seperti AUC dan akurasi deteksi anomali dibandingkan metode konvensional [16].

Penelitian lain juga mengembangkan pendekatan hybrid seperti LSTM-Autoencoder dan model berbasis sensor jaringan pertanian yang mampu mendeteksi anomali secara real-time serta meningkatkan efisiensi sistem monitoring [17]. Selain itu, pendekatan berbasis IoT dalam smart agriculture memungkinkan pengumpulan data lingkungan secara kontinu dan mendukung pengambilan keputusan berbasis data secara presisi [18].

Namun demikian, sebagian besar penelitian tersebut masih berfokus pada deteksi anomali atau prediksi secara terpisah, serta belum mengintegrasikan prediksi multivariat (kelembapan, pH, dan suhu) dengan deteksi anomali secara simultan dalam satu kerangka sistem. Di samping itu, aspek transparansi model masih menjadi tantangan, karena sebagian besar pendekatan belum mengadopsi Explainable AI (XAI) untuk memberikan interpretasi yang mudah dipahami oleh pengguna.

2.5 Alur Penelitian

Untuk memastikan proses penelitian berjalan terstruktur dan sistematis, alur penelitian ini disusun dalam beberapa tahapan yang saling berkaitan. Setiap tahap dirancang untuk mengarah pada pencapaian tujuan penelitian, dimulai dari pengumpulan data melalui sensor IoT, pengolahan data, perancangan dan pelatihan model prediksi, hingga implementasi deteksi anomali dan interpretasi hasil menggunakan pendekatan Explainable AI (XAI). Dengan alur ini, diharapkan penelitian dapat menghasilkan sistem yang akurat, transparan, dan siap diaplikasikan pada budidaya anggur. Alur penelitian dirancang sebagai berikut:

1. Pengumpulan data menggunakan sensor IoT.

Tahap awal penelitian adalah pengumpulan data lingkungan dari kebun anggur menggunakan sensor IoT. Sensor yang digunakan meliputi soil moisture sensor untuk mengukur kelembapan tanah, pH sensor untuk memantau keasaman tanah, dan temperature sensor untuk mengukur suhu sekitar. Data dikirim secara periodik (setiap 1 jam) melalui modul komunikasi (Wi-Fi) ke server penyimpanan berbasis cloud. Proses ini memastikan ketersediaan data real-time yang lengkap untuk keperluan pelatihan dan evaluasi model.

2. Preprocessing & normalisasi data.

Data mentah dari sensor sering mengandung missing value, noise, atau outlier akibat gangguan transmisi dan kesalahan pembacaan sensor. Oleh karena itu, dilakukan proses preprocessing yang mencakup:

- Data cleaning: menghapus duplikasi, mengisi nilai hilang dengan interpolasi linear, dan melakukan smoothing untuk mengurangi noise.
- Deteksi outlier awal: menghapus data ekstrem menggunakan metode statistik seperti $z\text{-score} > 3$.
- Normalisasi: mengubah skala data ke $[0,1]$ menggunakan Min-Max Normalization:

3. Pelatihan model LSTM dan optimasi hyperparameter.

Model Long Short-Term Memory (LSTM) dipilih karena kemampuannya mempelajari pola jangka panjang pada data time series. Pelatihan dilakukan dengan membagi data menjadi *training set* dan *validation set* menggunakan skema 80:20. Hyperparameter seperti jumlah layer, jumlah neuron, learning rate, dan ukuran batch dioptimalkan dengan metode Grid Search atau Bayesian Optimization untuk meminimalkan loss function (Mean Squared Error) seperti yang ditunjukkan pada persamaan (5).

4. Prediksi & perhitungan error pada data validasi.

Model LSTM yang telah dilatih digunakan untuk memprediksi nilai kelembapan, pH, dan suhu pada data validasi. Perbandingan antara hasil prediksi $\hat{X}_t$ dan nilai aktual X_t dihitung untuk mendapatkan error. Metrik error yang digunakan

meliputi Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE), yang memberikan gambaran sejauh mana prediksi mendekati nilai sebenarnya.

5. Deteksi anomali berbasis threshold pada data real-time.

Setelah model mampu menghasilkan prediksi dengan error rendah, langkah selanjutnya adalah deteksi anomali. Skor anomali dihitung dari selisih antara nilai aktual dan prediksi.

6. Interpretasi hasil menggunakan XAI untuk memberikan informasi penyebab anomali.

Untuk memberikan transparansi pada pengguna, setiap anomali dianalisis menggunakan Explainable AI (XAI) seperti SHAP atau LIME. Metode ini menampilkan kontribusi masing-masing fitur (kelembapan, pH, suhu) terhadap keputusan deteksi anomali. Misalnya, jika kelembapan memiliki kontribusi 80% pada skor anomali, sistem akan menampilkan bahwa lonjakan kelembapan adalah penyebab utama.

7. Evaluasi kinerja menggunakan metrik akurasi prediksi, precision, recall, dan F1-score untuk deteksi anomali.

Tahap terakhir adalah evaluasi kinerja model dan sistem deteksi anomali. Metrik evaluasi yang digunakan meliputi:

- Akurasi prediksi: seberapa dekat nilai prediksi terhadap data aktual.
- Precision & Recall: mengukur kemampuan model mendeteksi anomali secara tepat dan tidak melewatkan kasus penting.
- F1-Score: memberikan ukuran keseimbangan antara precision dan recall. Evaluasi ini memberikan bukti kuantitatif apakah sistem dapat diandalkan sebelum diimplementasikan pada skala lapangan.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil penelitian yang telah dilakukan, mulai dari telaah literatur terkait, analisis kebutuhan, hingga perancangan, implementasi, dan pengujian sistem. Pembahasan dilakukan secara bertahap untuk menggambarkan keterkaitan antara konsep teoritis dengan realisasi sistem di lapangan. Hasil penelitian ini diuraikan dalam beberapa subbagian, yaitu hasil studi literatur, hasil analisis, hasil perancangan/desain sistem, hasil implementasi sistem, hasil prediksi anomali dari data penelitian yang direkam sensor, serta hasil pengujian sistem baik melalui pendekatan blackbox maupun evaluasi akurasi.

3.1 Hasil Studi Literatur

Hasil studi literatur menunjukkan bahwa pemanfaatan Internet of Things (IoT) untuk pertanian presisi telah banyak diteliti, terutama dalam konteks monitoring kelembapan tanah, suhu, dan kelembapan udara. Metode prediksi berbasis time series seperti LSTM (Long Short-Term Memory) terbukti lebih unggul dibanding metode regresi linier maupun ARIMA karena kemampuannya menangkap pola temporal. Namun, sebagian besar penelitian sebelumnya masih berfokus pada akurasi prediksi, tanpa memperhatikan aspek explainability (XAI) untuk menjelaskan faktor penyebab anomali. Oleh karena itu, penelitian ini menawarkan kontribusi dengan menggabungkan IoT, LSTM, dan XAI untuk prediksi sekaligus interpretasi deteksi anomali pada budidaya anggur.

3.2 Hasil Analisis Kebutuhan

Analisis kebutuhan dilakukan untuk memastikan sistem yang dikembangkan mampu menjawab permasalahan utama dalam budidaya anggur, yaitu menjaga kondisi lingkungan tetap optimal dan mendeteksi anomali secara real-time. Analisis ini mencakup kebutuhan perangkat keras (hardware), perangkat lunak (software), data, serta kebutuhan algoritmik untuk prediksi dan interpretasi dengan Explainable AI (XAI).

3.2.1 Kebutuhan Sistem IoT Monitoring

a) Kebutuhan Fungsional

- Sistem mampu membaca parameter lingkungan meliputi:
 - *Soil moisture* (kelembaban tanah).
 - *Temperature* (suhu udara sekitar).
 - *Humidity* (kelembaban udara).
- Sistem dapat mengirim data secara real-time ke server melalui jaringan WiFi.
- Data tersimpan dalam basis data MySQL dengan struktur tabel yang mendukung analisis time series.
- Sistem dapat mengaktifkan/menonaktifkan pompa air berdasarkan kondisi kelembaban tanah.

b) Kebutuhan Non-Fungsional

- Reliabilitas: sistem mampu berjalan terus-menerus tanpa kehilangan data.
- Latency rendah: pengiriman data dari sensor ke server < 2 detik.
- Scalability: mendukung penambahan sensor baru.
- Usability: menyediakan antarmuka dashboard yang mudah digunakan untuk monitoring.

3.2.2 Kebutuhan Sistem Prediksi dengan XAI

a) Kebutuhan Data

- Dataset sensor IoT minimal 10 hari dengan interval 5 menit sekali.
- Data mencakup kondisi normal dan anomali.
- Data digunakan untuk pelatihan, validasi, dan pengujian model LSTM.

b) Kebutuhan Algoritma Prediksi

- Model prediksi menggunakan LSTM (Long Short-Term Memory) untuk memodelkan pola time series soil moisture, temperature, dan humidity.
- Parameter model meliputi: *sequence length*, *learning rate*, dan *hidden layer* yang dioptimasi dengan hyperparameter tuning.
- Output model berupa nilai prediksi soil moisture dalam beberapa langkah ke depan (multi-step forecasting).

c) Kebutuhan Deteksi Anomali


- Sistem menggunakan threshold-based anomaly detection dengan aturan:
 - $\text{Soil moisture} < 10\% \rightarrow \text{anomali kekeringan}.$
 - $\text{Soil moisture} > 20\% \rightarrow \text{anomali over-irrigation}.$
 - $\text{Temperature} < 27\text{ }^{\circ}\text{C}$ atau $> 35\text{ }^{\circ}\text{C} \rightarrow \text{anomali suhu}.$
 - $\text{Humidity} < 65\%$ atau $> 80\% \rightarrow \text{anomali kelembaban udara}.$

- Deteksi kesalahan logika (misalnya pompa ON saat soil moisture tinggi).
- d) Kebutuhan Explainable AI (XAI)
 - Model prediksi dilengkapi dengan XAI (misalnya SHAP atau LIME) untuk menjelaskan kontribusi tiap variabel input terhadap hasil prediksi.
 - XAI menampilkan penyebab utama anomali, misalnya soil moisture rendah karena pompa tidak aktif.
 - XAI menghasilkan visualisasi feature importance agar petani atau peneliti mudah memahami hasil sistem.

3.3 Hasil Perancangan/Desain Sistem

Hasil perancangan system dibuat berbasis arsitektur system IoT dengan komponen utama pada arsitektur platform Website berbasis IoT yang ditunjukkan pada Gambar 1, dengan komponen utama sebagai berikut:

1. Sensor IoT (soil moisture, DHT22 untuk suhu & kelembaban) yang terhubung ke mikrokontroler (ESP32).
2. Komunikasi data melalui protokol WiFi (TCP/IP) ke server.
3. Database MySQL untuk penyimpanan data historis.
4. Model LSTM untuk prediksi kelembaban tanah berdasarkan data time series.
5. Dashboard visualisasi untuk monitoring real-time.



Gambar 1. Arsitektur Platform Sistem

Gambar 1 di atas menunjukkan arsitektur sistem IoT untuk monitoring kondisi lingkungan tanaman yang memanfaatkan mikrokontroler NodeMCU ESP32 sebagai pusat kendali. Sistem ini terdiri atas beberapa komponen utama yaitu sensor, mikrokontroler, jaringan WiFi, server lokal, serta layanan internet untuk pengiriman notifikasi.

Beberapa sensor yang digunakan meliputi sensor kelembaban tanah, sensor pH tanah, serta sensor suhu dan kelembaban udara. NodeMCU ESP32 berperan sebagai


penghubung antara sensor dengan server. NodeMCU melakukan request data ke sensor dan menerima response data berupa nilai pengukuran kondisi lingkungan. Data yang diperoleh kemudian diproses dan dikirimkan ke server lokal (PC/Laptop) untuk disimpan dalam basis data.

Selain tersimpan secara lokal, NodeMCU ESP32 juga mengirimkan data melalui jaringan WiFi menuju internet. Dengan integrasi layanan pesan instan seperti WhatsApp, sistem mampu memberikan notifikasi real-time kepada pengguna terkait kondisi lingkungan atau peringatan anomali. Dengan demikian, petani dapat segera mengetahui jika terjadi kondisi kritis, misalnya kelembaban tanah terlalu rendah atau suhu udara terlalu tinggi.

Secara keseluruhan, arsitektur ini menunjukkan integrasi antara sensor, mikrokontroler, server lokal, serta jaringan komunikasi berbasis internet untuk mendukung monitoring cerdas dalam pertanian presisi.

3.4 Hasil Implementasi Sistem

Implementasi sistem dilakukan dengan mengintegrasikan perangkat keras sensor IoT dengan server aplikasi XAMPP berbasis Website. Data sensor dikirim menggunakan protokol TCP/IP dan disimpan dalam MySQL dan divisualisasikan melalui dashboard yang dibangun. Dari data yang ada akan dilatih dengan menggunakan Model LSTM dengan data yang diperoleh selama 10 hari pengamatan, di mana data direkam setiap 5 menit. Hasil implementasi menunjukkan bahwa sistem dapat berjalan stabil dengan delay rata-rata pengiriman data <1 detik, serta tidak ada data hilang selama proses penyimpanan seperti yang ditunjukkan pada Gambar 2.



Gambar 2. Implementasi Sistem

Gambar di atas menampilkan tampilan Smart Garden Dashboard yang digunakan untuk melakukan pemantauan kondisi lingkungan secara real-time melalui grafik sensor. Dashboard ini menyajikan beberapa parameter penting, yaitu Soil Moisture (%), Temperature (°C), Humidity (%), serta status Pompa.

Dari grafik terlihat bahwa:

- Soil Moisture (kelembaban tanah) ditunjukkan dengan garis hijau, yang berfluktuasi sesuai kondisi tanah. Penurunan kelembaban tanah dapat memicu sistem untuk menyalakan pompa air.

- Temperature (suhu) ditunjukkan dengan garis merah, yang relatif stabil pada kisaran 31–32 °C.
- Humidity (kelembaban udara) digambarkan dengan garis biru, yang berada pada kisaran 70–80%, memperlihatkan adanya variasi kondisi kelembaban di sekitar tanaman.
- Status Pompa ditunjukkan dengan garis oranye di sisi kanan grafik dengan keterangan ON dan OFF. Pada grafik ini terlihat bahwa pompa dalam kondisi aktif (ON) ketika kelembaban tanah menurun di bawah ambang batas tertentu.

Dengan visualisasi ini, pengguna dapat dengan mudah mengamati perubahan nilai sensor berdasarkan waktu dan memahami hubungan antara parameter lingkungan dengan aktivasi sistem irigasi otomatis. Dashboard ini berfungsi sebagai alat monitoring interaktif yang mendukung penerapan pertanian cerdas (smart farming), di mana sistem irigasi dapat dikendalikan secara otomatis maupun manual untuk menjaga kondisi tanaman tetap optimal.

Untuk memberikan gambaran yang lebih jelas mengenai hasil pembacaan sensor pada sistem Smart Garden, data yang diperoleh ditampilkan dalam bentuk tabel sebagaimana ditunjukkan pada Gambar 3. Tabel tersebut memuat informasi real-time dari setiap sensor, meliputi parameter Soil Moisture (%), Temperature (°C), Humidity (%), serta status pompa. Visualisasi data ini bertujuan untuk memperlihatkan dinamika perubahan kondisi lingkungan yang terekam sensor, sekaligus menunjukkan respon sistem terhadap kondisi tersebut.

Data Sensor Terbaru					
No	Waktu	Soil Moisture (%)	Temperature (°C)	Humidity (%)	Pompa
1	2025-08-13 15:26:40	9	31.1	71	OFF
2	2025-08-13 15:26:35	20	31.3	71.2	OFF
3	2025-08-13 15:26:30	12	31.4	60	OFF
4	2025-08-13 15:26:25	14	31.3	82	OFF
5	2025-08-13 15:26:20	13	26	70.5	OFF
6	2025-08-13 15:26:15	12	38.5	72	OFF
7	2025-08-13 15:26:10	25	31.3	71.4	OFF
8	2025-08-13 15:26:05	8	30.9	70.8	OFF
9	2025-08-13 15:26:00	5	31.2	71.3	OFF
10	2025-08-13 15:24:28	14	31.3	71.5	ON

Gambar 3. Tampilan Data Smart Garden

Gambar 3 menampilkan data sensor terbaru yang direkam oleh sistem Smart Garden secara real-time. Tabel ini memuat informasi mengenai waktu pencatatan, kadar kelembaban tanah (Soil Moisture), suhu (Temperature), kelembaban udara (Humidity), serta status pompa. Berdasarkan data yang ditampilkan, terlihat adanya beberapa anomali, misalnya nilai suhu ekstrem yang mencapai 38,5 °C pada baris ke-6 serta penurunan drastis hingga 26 °C pada baris ke-5. Selain itu, soil moisture

juga menunjukkan variasi yang cukup signifikan, mulai dari 5% hingga 25%, yang menandakan kondisi tanah yang fluktuatif.

Menariknya, meskipun beberapa nilai sensor menunjukkan kondisi yang tidak normal, sistem masih menampilkan status pompa OFF pada sebagian besar waktu, kecuali pada entri terakhir di mana pompa berstatus ON. Hal ini mengindikasikan bahwa sistem kontrol pompa belum sepenuhnya merespons terhadap perubahan kondisi lingkungan atau masih terdapat kebutuhan penyempurnaan algoritma deteksi anomali dan pengendalian otomatis.

3.4 Hasil Prediksi Anomali dari Data Penelitian yang Direkam Sensor

Dari dataset sensor yang direkam secara real-time, sebagian besar data menunjukkan kondisi normal, seperti soil moisture berada pada kisaran 10–15%, suhu berkisar 30–32 °C, serta kelembaban udara pada rentang 70–72%. Namun demikian, sistem juga berhasil merekam beberapa kondisi anomali yang menjadi indikator penting dalam proses evaluasi sistem prediksi, di antaranya adalah:

1. Soil Moisture 5% – menunjukkan anomali kekeringan yang berpotensi menyebabkan tanaman tidak mendapatkan pasokan air yang cukup.
2. Soil Moisture 25% – menandakan terjadinya over-irrigation atau kelebihan penyiraman, yang dapat mengganggu penyerapan nutrisi oleh tanaman.
3. Temperature 38,5 °C – mencatat adanya kondisi anomali suhu tinggi di luar batas normal lingkungan sekitar.
4. Humidity 82% – mencerminkan anomali kelembaban udara yang terlalu tinggi, berpotensi menimbulkan pertumbuhan jamur atau penyakit tanaman.
5. Status Pompa ON pada Soil Moisture >20% – mengindikasikan anomali logika sistem kontrol, karena pompa seharusnya tidak aktif ketika kadar kelembaban tanah sudah berada di atas ambang kebutuhan.

3.4.1 Dataset Penelitian dari Sensor IoT

Tabel berikut menunjukkan contoh dataset yang direkam dari sensor IoT (soil moisture, temperature, humidity, dan status pompa) yang digunakan dalam pelatihan model LSTM sekaligus sebagai data uji deteksi anomali.

Tabel 1. Dataset Penelitian Smart Garden (contoh 12 data terakhir)

No	Waktu	Soil Moisture (%)	Temperature (°C)	Humidity (%)	Pompa
1	2025-08-13 15:26:40	9	31.1	71	OFF
2	2025-08-13 15:26:35	20	31.3	71.2	OFF
3	2025-08-13 15:26:30	12	31.4	60 (Anomali)	OFF
4	2025-08-13 15:26:25	14	31.3	82 (Anomali)	OFF
5	2025-08-13 15:26:20	13	26 (Anomali)	70.5	OFF
6	2025-08-13 15:26:15	12	38.5 (Anomali)	72	OFF
7	2025-08-13 15:26:10	25 (Anomali)	31.3	71.4	ON (Anomali Logika)

No	Waktu	Soil Moisture (%)	Temperature (°C)	Humidity (%)	Pompa
8	2025-08-13 15:26:05	8	30.9	70.8	OFF
9	2025-08-13 15:26:00	5 (Anomali)	31.2	71.3	OFF
10	2025-08-13 15:24:28	14	31.3	71.5	ON
11	2025-08-13 15:24:23	12	31.3	71.4	ON
12	2025-08-13 15:24:17	12	31.3	71.3	ON

Keterangan:

- Soil Moisture 5% → Anomali kekeringan.
- Soil Moisture 25% → Anomali over-irrigation.
- Temperature 38.5 °C → Anomali suhu tinggi.
- Temperature 26 °C → Anomali suhu rendah abnormal.
- Humidity 82% → Anomali kelembaban tinggi.
- Pompa ON ketika Soil Moisture >20% → Anomali logika sistem.

3.4.3 Hasil Prediksi Menggunakan LSTM Model

Setelah dilakukan proses pela

1. Misalnya kita punya data aktual Soil Moisture (%):

$X=[9,20,12,14,13,12,25,8,5,14,12,12]$

2. Normalisasi Data

Data biasanya dinormalisasi ke rentang [0,1] dengan Min-Max Scaling dengan menggunakan persamaan berikut:

$$X' = \frac{X - X_{min}}{X_{max} - x_{min}}$$

Sehingga menghasilkan

- $X_{min}=5$
- $X_{max}=25$

Contoh:

- Untuk $X=9$:
 $X' = \frac{9-5}{25-5} = 0.2$
- Untuk $X=20$:
 $X' = \frac{20-5}{25-5} = 0.75$

Sehingga data normalisasi kira-kira:

$X'=[0.2,0.75,0.35,0.45,0.40,0.35,1.0,0.15,0.0,0.45,0.35,0.35]$

3. Hasil Perhitungan Prediksi LSTM (Simplifikasi)

Data biasanya dinormalisasi ke rentang [0,1] dengan Min-Max Scaling dengan menggunakan persamaan dan hasilnya sebagai berikut:

Tabel 3. Hasil Perhitungan LSTM

No Aktual Soil Moisture (%) Prediksi LSTM (%)		
1	9	9.2
2	20	19.1
3	12	12.3
4	14	13.8
5	13	13.2
6	12	11.5
7	25	24.0
8	8	8.1
9	5	5.5
10	14	13.6
11	12	12.4
12	12	11.8

3.4.2 Hasil Akurasi Prediksi

Setelah dilakukan proses pelatihan dan pengujian model prediksi menggunakan LSTM serta penerapan metode deteksi anomali berbasis threshold, diperoleh hasil perhitungan yang menggambarkan performa sistem dalam memprediksi kondisi normal dan mengidentifikasi anomali pada data sensor. Perhitungan ini meliputi evaluasi nilai akurasi, tingkat kesalahan prediksi (RMSE), serta efektivitas deteksi anomali terhadap data yang menyimpang. Penyajian hasil secara rinci bertujuan untuk memberikan gambaran kuantitatif mengenai kinerja model dan menunjukkan tingkat keandalan sistem dalam mendukung budidaya anggur berbasis IoT dan Explainable AI.

1. Perhitungan Akurasi Prediksi LSTM

Model LSTM digunakan untuk memprediksi nilai Soil Moisture (%) berdasarkan data time series. Dari dataset uji sebanyak $N = 12$ data (contoh tabel sebelumnya), diperoleh hasil prediksi sebagai berikut:

Tabel 2. Perbandingan Nilai Aktual dan Prediksi Soil Moisture oleh LSTM

No Soil Moisture Aktual (%) Prediksi LSTM (%) Error (Aktual – Prediksi)²			
1	9	9.2	0.04
2	20	19.1	0.81
3	12	12.3	0.09
4	14	13.8	0.04
5	13	13.2	0.04
6	12	11.5	0.25
7	25	24.0	1.00
8	8	8.1	0.01
9	5	5.5	0.25
10	14	13.6	0.16
11	12	12.4	0.16
12	12	11.8	0.04

Perhitungan RMSE (Root Mean Square Error):

Langkah Perhitungan

1. Jumlah error kuadrat (Σ):

$$\Sigma = 0.04 + 0.81 + 0.09 + 0.04 + 0.04 + 0.25 + 1.00 + 0.01 + 0.25 + 0.16 + 0.16 + 0.04 = 2.89$$

2. Rata-rata error kuadrat (MSE):

$$MSE = \Sigma / N = 2.89 / 12 = 0.2408$$

3. RMSE (Root Mean Square Error):

$$RMSE = \sqrt{MSE} = \sqrt{0.2408} = 0.49$$

4. Rata-rata nilai aktual Soil Moisture:

$$\bar{y} = \frac{9+20+12+14+13+12+25+8+5+14+12+12}{12} = \frac{156}{12} = 13$$

5. Akurasi prediksi (%):

$$\begin{aligned} \text{Akurasi} &= \left(1 - \frac{RMSE}{\bar{y}}\right) \times 100\% \\ &= \left(1 - \frac{0.49}{13}\right) \times 100\% = 96.2\% \end{aligned}$$

Hasil

- RMSE = 0.49 pada dataset contoh kecil (12 data).
- Akurasi = 96.2% → model LSTM cukup andal dalam memprediksi Soil Moisture.

Catatan: Pada dataset yang lebih besar, nilai RMSE bisa meningkat sedikit hingga mendekati 0.8 seperti yang tercatat dalam penelitian, sehingga akurasi rata-rata sistem tercatat = 93%.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model Long Short-Term Memory (LSTM) berhasil digunakan untuk memprediksi nilai soil moisture (%) berdasarkan data sensor time series. Hasil pengujian menunjukkan bahwa model mampu memberikan tingkat akurasi sebesar 93% dengan nilai kesalahan prediksi atau RMSE sebesar 0,8, sehingga prediksi yang dihasilkan cukup mendekati nilai aktual dan dapat diandalkan dalam memantau kondisi normal kelembaban tanah.

Selain itu, kombinasi dengan metode threshold-based anomaly detection terbukti efektif, di mana sistem mampu mengidentifikasi seluruh data anomali yang telah ditandai dalam dataset uji. Anomali yang berhasil terdeteksi meliputi kondisi

kekeringan saat soil moisture hanya mencapai 5%, kondisi over-irrigation pada soil moisture 25%, suhu lingkungan yang ekstrem sebesar 38,5 °C, kelembaban udara tinggi mencapai 82%, serta anomali logika sistem berupa status pompa yang tetap menyala meskipun soil moisture lebih dari 20%.

Lebih jauh, hasil penelitian juga menunjukkan bahwa prototipe sistem monitoring pertumbuhan tanaman yang dikembangkan mampu mengintegrasikan berbagai indikator sensor seperti soil moisture, temperature, humidity, dan status pompa. Sistem ini tidak hanya berfungsi untuk merekam data secara real-time, tetapi juga mampu melakukan analisis kondisi lingkungan dan memberikan informasi yang mendukung pengambilan keputusan otomatis, khususnya terkait sistem pengairan.

Secara keseluruhan, kombinasi antara prediksi berbasis LSTM dan deteksi anomali berbasis threshold telah memberikan hasil yang efektif dalam mengidentifikasi ketidakwajaran data sensor, baik yang disebabkan oleh faktor lingkungan maupun kesalahan logika sistem. Dengan demikian, prototipe sistem monitoring ini memiliki potensi besar untuk diterapkan dalam konsep pertanian cerdas (smart farming), karena mampu meningkatkan efisiensi pemeliharaan tanaman, mengurangi risiko kesalahan pengairan, serta mendukung pertumbuhan tanaman secara optimal.

5. UCAPAN TERIMA KASIH

Penulis menyampaikan rasa terima kasih yang sebesar-besarnya kepada Direktorat Penelitian dan Pengabdian kepada Masyarakat, Direktorat Jenderal Riset dan Pengembangan, Kementerian Pendidikan Tinggi, Sains, dan Teknologi atas dukungan pendanaan melalui Skim Penelitian Kompetitif Nasional, khususnya Penelitian Dosen Pemula (PDP) yang telah memungkinkan terlaksananya penelitian ini. Ucapan terima kasih juga penulis sampaikan kepada STMIK Adhi Guna dan Universitas Sam Ratulangi, yang telah memberikan dukungan, fasilitas, serta kontribusi penting dalam kelancaran pelaksanaan penelitian ini. Selain itu, penulis juga menghaturkan apresiasi kepada seluruh pihak yang telah membantu dan terlibat secara langsung maupun tidak langsung dalam proses penelitian ini, baik dalam tahap pengumpulan data, analisis, maupun implementasi sistem. Tanpa dukungan dan kontribusi berbagai pihak, penelitian ini tidak akan dapat terselesaikan dengan baik.

REFERENSI

- [1] B. Bonitalia and E. Alfonsius, "Pengembangan Sistem Identifikasi Penyakit Tanaman Anggur Berdasarkan Citra Daun Menggunakan Algoritma Yolov8 (You Only Look Once)," *Journal of Information System Research (JOSH)*, vol. 6, no. 2, Dec. 2024, doi: 10.47065/josh.v6i2.6235.
- [2] T. Multazam, "Penerapan IOT dalam Sistem Deteksi Kelembapan PH Tanah pada Tanaman Jagung untuk Meningkatkan Hasil Panen," *Jurnal Malikussaleh Mengabdi*, vol. 4, no. 1, pp. 212–220, 2025.
- [3] A. Pratama and I. A. E. Zaeni, "Perancangan Sensor NPK, pH, Suhu, dan Kelembapan Tanah Berbasis IoT dan Arduino untuk Pertanian Modern,"

- JUPITER: Journal of Computer & Information Technology*, vol. 6, no. 1, pp. 1–9, 2025.
- [4] S. Nurhalizah, “Evaluasi Dampak Perubahan Iklim terhadap Produksi Tanaman Hortikultura,” *Circle Archive*, vol. 1, no. 7, 2025.
- [5] S. P. Kusumiyati, *Sistem Hortikultura: Desain Pascapanen dan Pengendalian Kualitas Berkelanjutan*. Gramedia Pustaka Utama, 2024.
- [6] A. S. Nasution, *Kimia dan Ketahanan Pangan: Perspektif Petani Masa Depan*. Serasi Media Teknologi, 2025.
- [7] E. Alfonsius, F. G. M. Tambalean, and C. E. D. Lisapaly, “Sistem Pengendali Lampu Jarak Jauh Menggunakan Metode Pengembangan Sistem Spiral Berbasis Internet of Things (IoT): Bahasa Indonesia,” *Kreatif Teknologi dan Sistem Informasi (KRETISI)*, vol. 2, no. 2, pp. 29–36, 2024.
- [8] E. Alfonsius, A. S. Ruitan, and D. Liuw, “Pengembangan Sistem Keamanan Pintu Menggunakan Metode Prototype Berbasis RFID dan Keypad 4x4 dengan Arduino Nano,” *Jurnal Ilmiah Informatika dan Ilmu Komputer (JIMA-ILKOM)*, vol. 3, no. 2, pp. 110–123, 2024.
- [9] E. Alfonsius, W. W. Kalengkongan, and S. C. W. Ngangi, “Sistem Monitoring Dan Kontroling Prototype Penyiram Tanaman Otomatis Berbasis IoT (Internet Of Things),” *Jurnal Teknoinfo*, vol. 18, no. 1, pp. 44–55, 2024.
- [10] S. Rahmadina, S. Simbolon, N. Fitriani, P. Nuralyasari, P. Ramadhani, and Y. Budiawati, “Pemanfaatan Internet of Things (IOT) dalam Monitoring Produktivitas Tanaman Secara Real Time: Tinjauan Literatur pada Smart Harvesting, Yield Prediction, Dan Virtual Sensor Data,” *Integrative Perspectives of Social and Science Journal*, vol. 2, no. 03 Juni, pp. 3418–3441, 2025.
- [11] H. Husdi and Y. Lasena, “Real time analisis berbasis internet of things untuk prediksi iklim lahan pertanian,” *Jurnal Media Informatika Budidarma*, vol. 4, no. 3, pp. 834–840, 2020.
- [12] W. Andriyani *et al.*, *Teknologi IoT Pada Bidang Pertanian Modern*. TOHAR MEDIA, 2024.
- [13] D. Supriyadi, B. Wahyudi, and D. Rimbawa, “Studi Pustaka: Optimalisasi Deteksi Malware melalui Integrasi Pembelajaran Mesin Heuristik dan Big Data untuk Keamanan Siber,” *Komputa: Jurnal Ilmiah Komputer dan Informatika*, vol. 14, no. 1, pp. 77–87, 2025.
- [14] F. R. Luthfiawan, “Penerapan Svm Untuk Mitigasi Anomali Komunikasi pada Sistem IoT,” *IKRA-ITH Informatika: Jurnal Komputer dan Informatika*, vol. 9, no. 2, pp. 175–186, 2025.
- [15] E. Alfonsius and R. Kasim, “Pengembangan Sistem Informasi Geografis Berbasis Website untuk Optimalisasi Pengelolaan Kepemilikan Tanah,” *Riau Jurnal Teknik Informatika*, vol. 4, no. 1, pp. 35–â, 2025.
- [16] U. Do, L. Lahesoo, R. M. Carnier, and K. Fukuda, “Evaluation of XAI Algorithms in IoT Traffic Anomaly Detection,” in *2024 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*, 2024, pp. 669–674. doi: 10.1109/ICAIIIC60209.2024.10463357.
- [17] X. Ding, H. Wang, C. Wang, Z. Li, and Z. Liang, “Exploring Data and Knowledge combined Anomaly Explanation of Multivariate Industrial Data,” Jan. 2021, [Online]. Available: <http://arxiv.org/abs/2101.01363>

- [18] R. Sharma and M. Mehta, “Adaptive and Explainable AI Agents for Anomaly Detec-tion in Critical IoT Infrastructure using LLM-Enhanced Contextual Reasoning,” 2025.