

Sistem Irigasi Presisi Dengan Prediksi Cuaca Menggunakan Algoritma Random Forest Berbasis Aplikasi Blynk

1st Reynanda Shaquille Purwanto
Program Studi Teknologi Informasi
Universitas Telkom, Kampus Surabaya
Surabaya, Indonesia
reynandashaqa@student.telkomuniversity.ac.id

2nd Helmy Widyantara
Program Studi Teknologi Informasi
Universitas Telkom, Kampus Surabaya
Surabaya, Indonesia
helmywidyantara@telkomuniversity.ac.id

3rd Muhammad Adib Kamali
Program Studi Teknologi Informasi
Universitas Telkom, Kampus Surabaya
Surabaya, Indonesia
adibmkamali@telkomuniversity.ac.id

Abstrak — Budidaya kelengkeng di lingkungan terbatas seperti rooftop menghadapi tantangan dalam manajemen air yang efisien akibat dinamika lingkungan dan kebutuhan tanaman yang spesifik. Sistem irigasi konvensional seringkali tidak efektif dan menyebabkan pemborosan sumber daya. Penelitian ini bertujuan merancang, membangun, dan menguji sistem irigasi presisi yang mengintegrasikan *Internet of Things* (IoT) untuk pemantauan dan *Machine Learning* untuk pengambilan keputusan penyiraman secara cerdas dan otomatis. Sistem ini menggunakan mikrokontroler ESP32 yang terhubung dengan sensor kelembaban tanah, suhu dan kelembaban udara, curah hujan, dan kecepatan angin untuk mengumpulkan data yang dapat dipantau melalui aplikasi Blynk. Dua model *Machine Learning* dengan algoritma *Random Forest* dikembangkan: satu model klasifikasi untuk prediksi cuaca (hujan/tidak hujan) dan satu model regresi untuk penentuan durasi irigasi. Model-model ini dilatih dan dievaluasi menggunakan dataset aktual yang dikumpulkan dari lapangan. Hasil pengujian menunjukkan performa model yang baik. Model klasifikasi untuk prediksi cuaca mencapai akurasi keseluruhan sekitar 0.73 (73%), presisi 0.82 untuk kelas 'Hujan', dan *recall* 0.96 untuk kelas 'Tidak Hujan'. Ini membuktikan kemampuan model untuk mendeteksi kondisi tidak hujan secara andal, sementara presisi yang cukup tinggi pada kelas 'Hujan' membantu menghindari penyiraman yang tidak perlu. Sementara itu, model regresi untuk penentuan durasi irigasi mencapai *Mean Squared Error* (MSE) sebesar 43.72 detik² dan koefisien determinasi (R^2) 0.89. Hasil ini mengindikasikan bahwa model mampu mempelajari pola dari parameter lingkungan dan mengubahnya menjadi estimasi durasi penyiraman yang presisi dan andal. Integrasi IoT dan *Machine Learning* ini terbukti berhasil menciptakan sistem irigasi yang cerdas dan efisien, mampu mengoptimalkan penggunaan air dan mendukung pertanian urban yang berkelanjutan di lingkungan yang menantang.

Kata kunci— Irigasi Presisi, *Internet of Things*, *Machine Learning*, *Random Forest*, Tanaman Kelengkeng, ESP32.

I. PENDAHULUAN

Pertanian adalah salah satu sektor ekonomi paling penting di dunia, yang bertanggung jawab untuk

menyediakan makanan bagi populasi global yang terus bertambah [1]. Tanaman, termasuk tanaman buah kelengkeng, sangat bergantung pada ketersediaan air. Meskipun kelengkeng (*Dimocarpus longan*) adalah salah satu tanaman pertanian yang sangat menguntungkan dan menghasilkan banyak pundi-pundi rupiah, budidayanya sangat bergantung pada ketersediaan air yang ideal untuk mendukung pertumbuhan dan kualitas buah.

Menurut penelitian [2] dalam artikel mereka berjudul "Perubahan jangka panjang dalam aktivitas biologi tanah dan sifat lain dari tanah yang ditanam di kebun kelengkeng *Longan*", menjelaskan bahwa ketersediaan air yang tepat dan mencukupi berpotensi besar pada kesuksesan panen kelengkeng. Terutama pada fase penting pertumbuhan kelengkeng, yang berdampak langsung pada kesehatan tanah dan sifat fisikokimianya. Dalam hal ini, pengembangan sistem irigasi cerdas dianggap sebagai jalan keluar yang efektif untuk meningkatkan efisiensi penggunaan air dalam pertanian [3]. Sistem dirancang menggunakan teknologi canggih seperti sensor kelembaban tanah, temperatur dan suhu udara, tetapan air hujan, kecepatan udara, serta sensor aliran air yang terhubung dengan mikrokontroler sebagai kontrol pusat. Data dapat dipantau langsung melalui aplikasi Blynk. Parameter-parameter sensor tersebut didapatkan hanya dari area yang terdapat implementasi sensor.

Akses kontrol yang dirancang terdapat 2 mode, yaitu mode kontrol jarak jauh dan kontrol otomatis, yang dapat mengatur penggunaan air secara kondisi lingkungan sekitar dan berdasar kebutuhan tanaman. Selain teknologi IoT, konsep irigasi presisi saat ini semakin berkembang dan memberikan solusi yang menyeluruh terhadap permasalahan penggunaan air di sektor pertanian. Irigasi presisi merupakan pendekatan berbasis teknologi yang secara akurat mengatur jumlah, waktu, dan lokasi penyiraman berdasarkan kebutuhan spesifik tanaman dan kondisi lingkungan secara aktual. Implementasi irigasi presisi memanfaatkan data sensor yang detail serta model prediktif untuk meminimalkan pemborosan air dan memaksimalkan hasil panen, sekaligus menjaga keberlanjutan pertanian serta kesehatan tanah [4]. Hanya dengan penggunaan teknologi IoT dirasa kurang

cukup karena sistem masih terbilang semi-manual, oleh karena itu peneliti menggunakan pendekatan *machine learning*, yang difokuskan untuk memprediksi cuaca dan menentukan durasi irigasi dari parameter sensor (Soil Moisture, SHT31-D, RainDrop, dan Anemometer).

Data yang diolah untuk prediksi cuaca dan penentuan durasi irigasi menggunakan *machine learning* dipilih karena teknologinya yang canggih dan pintar, serta dapat bekerja secara otomatis melalui proses pembelajaran yang dikenal dengan *training*, sehingga *machine learning* nanti akan dapat membuat keputusan secara otomatis [5]. Perpaduan antara teknologi IoT dengan *machine learning* akan menjadi satu kesatuan yang kompleks dan menjadi jawaban baru dari keterbatasan metode konvensional yang seringkali tidak efektif penggunaannya.

II. KAJIAN TEORI

A. Pertanian Presisi dan Irigasi Cerdas

Pertanian presisi merupakan sebuah pendekatan dalam manajemen pertanian yang memanfaatkan teknologi informasi untuk memastikan tanaman dan tanah menerima input yang tepat dalam hal jumlah, jenis, dan waktu aplikasi. Prinsip utamanya adalah memberikan perlakuan yang tepat, di lokasi yang tepat, dan pada waktu yang tepat untuk mengelola variabilitas temporal dan spasial secara optimal [6]. Salah satu implementasi dari pertanian presisi adalah sistem irigasi cerdas, yang menggunakan sensor lingkungan dan kecerdasan buatan untuk mengatur jadwal dan volume irigasi secara otomatis dan *real-time* [7]. Dibandingkan dengan sistem irigasi konvensional yang seringkali boros air, irigasi cerdas berbasis sensor dan AIoT terbukti mampu mengurangi konsumsi air hingga 30-64 persen dan meningkatkan produktivitas lahan hingga 20-25 persen [8].

B. Teknologi Internet of Things (IoT) dalam Pertanian

Penerapan IoT dalam pertanian melibatkan integrasi antara perangkat sensor, mikrokontroler seperti ESP32, jaringan komunikasi, dan platform *cloud* untuk pemantauan serta pengendalian jarak jauh. Sistem ini memanfaatkan beragam sensor untuk mengumpulkan data lingkungan secara akurat [9], di antaranya:

1. *Sensor Kelembapan Tanah (Soil Moisture)*, pada gambar 1.



Gambar 1
(Sensor Soil Moisture)

2. Sensor suhu dan kelembapan udara (SHT31-D), pada gambar 2.



Gambar 2
(Sensor SHT31-D)

3. Sensor curah hujan (*RainDrop Ombrometer*), pada gambar 3.



Gambar 3
(Sensor RainDrop Ombrometer)

4. Sensor Kecepatan Udara (*Sensor Anemometer JL-FS2*), Pada gambar 4.



Gambar 4
(Sensor Anemometer JL-FS2)

5. Sensor Aliran Air, Pada gambar 5.



Gambar 5
(Sensor Waterflow FS3000A)

Data yang terkumpul dari sensor-sensor ini kemudian diolah oleh mikrokontroler ESP32 dan dapat dipantau melalui platform IoT seperti Blynk, yang memungkinkan pengguna untuk mengontrol sistem melalui aplikasi *mobile* dengan antarmuka yang mudah digunakan [10].

C. Machine Learning untuk Irigasi Presisi

Machine learning (ML) adalah cabang dari kecerdasan buatan yang memungkinkan sistem untuk belajar dari data historis guna membuat prediksi tanpa harus diprogram secara eksplisit [11]. Dalam penelitian ini, algoritma *Random Forest* digunakan untuk dua tujuan utama:

1. Klasifikasi Prediksi Cuaca

Algoritma *Random Forest* untuk klasifikasi digunakan untuk memprediksi kondisi cuaca, seperti hujan atau tidak hujan, berdasarkan data dari sensor. Algoritma ini membangun beberapa pohon keputusan dan mengambil keputusan berdasarkan suara mayoritas (*voting*) dari semua pohon tersebut. Kinerja setiap pemisahan dalam pohon diukur menggunakan metrik seperti *Gini Impurity* atau *Information Gain* [12]. metrik yang paling umum digunakan

secara default dalam implementasi seperti Scikit-learn, berfungsi untuk mengukur "kemurnian" suatu node. Nilai Gini Impurity dihitung dengan rumus:

$$\text{Gini}(p) = 1 - \sum_{i=1}^C p_i^2 \quad (1)$$

Dimana C adalah jumlah kelas dan p_i adalah proporsi data kelas ke- i di node tersebut. Nilai Gini minimum (0) menunjukkan bahwa node tersebut "murni", artinya semua data di dalamnya berasal dari satu kelas. Alternatif lain adalah *Entropy*, yang dihitung dengan rumus:

$$\text{Entropy}(p) = - \sum_{i=1}^C p_i \cdot \log_2(p_i) \quad (2)$$

Entropy kemudian digunakan untuk menghitung Information Gain, yang merupakan perbedaan antara *Entropy parent node* dengan rata-rata Entropy dari *child nodes* setelah pemisahan.

2. Regresi untuk Penentuan Durasi Irigasi

Random Forest juga diterapkan sebagai model regresi untuk menentukan durasi penyiraman yang optimal. Model ini memprediksi nilai kontinu (durasi) dengan merata-ratakan hasil prediksi dari banyak pohon keputusan. Proses ini bertujuan untuk meminimalkan *Mean Squared Error* (MSE) guna menemukan pemisahan data yang paling efektif [13]. MSE bisa dihitung dengan persamaan dibawah ini:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 \quad (3)$$

n merepresentasikan jumlah sampel yang ada di dalam node tersebut. Nilai y_i adalah nilai aktual dari sampel ke- i , dan $\bar{y}$ adalah nilai rata-rata dari semua sampel yang berada di dalam node tersebut. Tujuan utama dari proses ini adalah untuk menemukan pemisahan yang dapat meminimalkan total MSE dari dua subset data yang dihasilkan setelah pemisahan dilakukan. Pengembangan model ML ini melalui beberapa tahapan, mulai dari pengumpulan data, prapemrosesan, pemilihan fitur, pelatihan model, hingga validasi dan evaluasi performa.

3. Budidaya Tanaman Kelengkeng

Kelengkeng (*Dimocarpus longan*) adalah tanaman buah tropis yang pertumbuhannya sangat dipengaruhi oleh ketersediaan air dan kondisi lingkungan. Kebutuhan air tanaman ini berbeda-beda di setiap fase pertumbuhan, mulai dari vegetatif hingga pematangan buah, sehingga manajemen air yang tepat sangat krusial untuk kualitas dan kuantitas panen [8]. Lingkungan ideal bagi tanaman kelengkeng adalah lokasi dengan suhu hangat (25-35°C), kelembaban sedang hingga tinggi, dan paparan sinar matahari yang cukup [8].

III. METODE

A. Sistematika Penyelesaian Masalah

Penelitian ini diawali dengan identifikasi masalah utama, yaitu rendahnya efisiensi penggunaan air pada budidaya kelengkeng di atap (*rooftop*) akibat metode penyiraman manual dan cuaca yang tidak menentu. Kondisi ini berpotensi menyebabkan stres pada tanaman dan pemborosan air. Untuk mengatasi hal ini,

dikembangkan sebuah sistem irigasi cerdas yang mengintegrasikan perangkat keras, IoT, dan *machine learning* untuk melakukan irigasi secara otomatis berdasarkan data lingkungan yang aktual [14]. Perangkat keras dan lunak yang digunakan dalam penelitian ini dapat dilihat pada tabel 1 dan 2.

Tabel 1
(Perangkat Keras)


Hardware	Spesifikasi
Laptop	Intel Core i5-11320H / 16GB / 500GB
ESP32	240MHz / SRAM 520kb / flash 4MB / 3.3V
Pompa air	220V
Anemometer JL-FS2	12-24V / 40°C - 80°C
Curah hujan Ombrometer	3.3-5V
Waterflow FS3000A	5-24V / 1-60 (L/menit)
SHT31-D	3-5V
Soil Moisture	-40°C - 80°C / 9-30V


Tabel 2
(Perangkat Lunak)

Software	Spesifikasi
Google Colab	versi 2025
Python	versi 3.12.10
Arduino IDE	versi 2.3.6
VSCode	versi 2025

B. Prosedur Penelitian

Untuk memastikan bahwa penelitian ini akan dapat terselesaikan dengan terarah penulis merancang prosedur penelitian untuk menghasilkan suatu sistem irigasi presisi dengan menggunakan algoritma *Random Forest* secara sistematis. Adapun berikut adalah langkah-langkah alur prosedur yang merupakan gambaran detail dari kegiatan penelitian yang dilakukan yang terbagi menjadi dua bagian utama, seperti terlihat pada Gambar 6.





Gambar 6
(Alur Prosedur)

Pada gambar 6 ini menunjukkan diagram alir keseluruhan proses penelitian, mulai dari Analisis Situasi, Pengumpulan Data, Rancangan Sistem, Pembuatan Prototipe, hingga Uji Coba dan Implementasi.

1. Analisis Situasi

Tahap awal ini bertujuan untuk menganalisis hubungan antara faktor lingkungan (kondisi sekitar, kelembaban tanah, kebutuhan air tanaman) dengan sistem irigasi yang ada. Hasil dari analisis ini menjadi dasar untuk merinci kebutuhan fungsional dari sistem yang akan dikembangkan.

2. Pengumpulan Data


Data dikumpulkan dengan menempatkan sensor-sensor di area penanaman kelengkeng di atap gedung Telkom University Surabaya. Sensor Anemometer, Raindrop, dan SHT31-D ditempatkan lebih tinggi dari tanaman untuk menangkap data lingkungan yang optimal, sedangkan sensor *Soil Moisture* ditanam di media tanam dan *Waterflow* dipasang pada pipa irigasi. Data yang dikumpulkan berupa data numerik dari seluruh sensor dalam berbagai kondisi cuaca dan waktu. Selain data sensor lingkungan, data volume air juga dikumpulkan dari sensor *waterflow* (FS3000A) menggunakan perhitungan berdasarkan frekuensi pulsa yang terdeteksi.

$$\text{Laju Aliran (L/jam)} = \frac{\text{Frekuensi Pulsa (Hz)} \times 60}{5.5} \quad (4)$$

Faktor 5.5 dalam rumus tersebut merupakan faktor kalibrasi dari sensor FS3000A. Data ini digunakan untuk melatih dan mengevaluasi model *Random Forest Regresi*.

C. Perancangan Sistem

Sistem yang dirancang mengintegrasikan beberapa komponen utama untuk menciptakan sistem irigasi yang otomatis dan cerdas hal ini dapat terlihat pada gambar 7.



Gambar 7
(Diagram Sistem)

Diagram sistem ini mengilustrasikan arsitektur dan alur kerja sistem irigasi presisi secara menyeluruh. Proses dimulai dengan berbagai sensor mencakup Anemometer, SHT31-D, Rain gauge, dan Soil Moisture sensor yang bertugas mengumpulkan data lingkungan secara *real-time*. Seluruh data dari sensor ini dikumpulkan oleh mikrokontroler ESP32, yang kemudian mengirimkannya ke *database cloud* untuk penyimpanan dan analisis lebih lanjut.

Data yang tersimpan di *cloud* ini digunakan sebagai input untuk model *machine learning* Random Forest, yang memiliki dua fungsi utama: memprediksi cuaca dan menentukan durasi irigasi yang dibutuhkan tanaman. Model ini diintegrasikan ke dalam sistem menggunakan FastAPI, yang berfungsi sebagai jembatan komunikasi antara *backend* sistem dan aplikasi pemantauan. Hasil akhir dari model, seperti keputusan durasi irigasi dan status pompa, kemudian dikirimkan ke platform Blynk. Melalui aplikasi Blynk, pengguna dapat dengan mudah memantau seluruh informasi dan status sistem melalui perangkat seluler atau *browser*.

D. Uji Coba dan Implementasi

Tahap akhir adalah pengujian dan penyempurnaan sistem secara berulang untuk memastikan efisiensi, akurasi, dan keandalannya. Model yang telah diintegrasikan dengan *backend* FastAPI dan ESP32 diuji secara menyeluruh di lapangan. Kinerja model dievaluasi menggunakan metrik statistik seperti presisi untuk model klasifikasi, serta *R-squared (R2 Score)* dan *Mean Squared Error (MSE)* untuk model regresi.

IV. HASIL DAN PEMBAHASAN

A. Pengumpulan dan Pengolahan Data

Data penelitian dikumpulkan secara aktual dari lingkungan *rooftop* menggunakan serangkaian sensor yang terintegrasi dengan mikrokontroler ESP32. Sensor-sensor ini mencakup kelembaban tanah (*soil moisture*), suhu dan kelembaban udara (SHT31-D), kecepatan angin, dan curah hujan. Data dikirimkan setiap menit ke *database* InfluxDB selama rentang waktu pengamatan (06.00-16.00 WIB). Sebelum digunakan, seluruh data mentah dari sensor yang telah dikalibrasi diolah melalui tahap pembersihan, pembentukan fitur, dan pelabelan. Dataset akhir yang digunakan untuk pelatihan model mencakup lima fitur utama. Hal tersebut dapat dilihat pada tabel 3.

Tabel 3
(Variabel Dataset Sensor)

No	Fitur	Deskripsi	Satuan
1	Temperature	Suhu udara	°C
2	Humidity	Kelembaban udara	%
3	Moisture	Kelembaban tanah	%
4	Wind Speed	Kecepatan angin	m/s
5	Rainfall	Curah hujan	mm

Data dikirim ke *database* setiap menit antara pukul 06.00 hingga 16.00 WIB dan digunakan untuk melatih dua model *machine learning* dengan algoritma Random Forest: satu model klasifikasi untuk prediksi cuaca dan satu model regresi untuk penentuan durasi irigasi. Data mentah kemudian melalui tahap pembersihan dan diproses menggunakan *StandardScaler* sebelum digunakan untuk pelatihan model.

B. Hasil Pelatihan dan Evaluasi Model

1. Evaluasi Model Prediksi Cuaca (Klasifikasi)

Model klasifikasi dilatih dalam beberapa kali percobaan untuk memprediksi kondisi cuaca ('Hujan' atau 'Tidak Hujan'). Dari serangkaian eksperimen, Model 3 dipilih sebagai yang terbaik untuk implementasi. Seperti yang ditunjukkan pada tabel 4.

Tabel 4
(Konfigurasi Percobaan Model Klasifikasi Prediksi Cuaca)

No	n_estimators	max_depth	min_samples_split	min_samples_leaf	criterion
1	348	37	6	3	entropy
2	406	36	2	5	entropy
3	494	47	7	2	gini
4	129	20	7	4	entropy

Pada Tabel ini menampilkan metrik evaluasi dari model klasifikasi yang terpilih. Model terpilih ini, yang menggunakan kriteria 'gini' dengan max_depth 47 dan n_estimators 494, mencapai akurasi keseluruhan sekitar 0.73. Alasan utama pemilihan model ini adalah performanya pada metrik spesifik: ia memiliki *precision* 0.82 untuk kelas 'Hujan' dan *recall* 0.96 untuk kelas 'Tidak Hujan'. Nilai *precision* yang tinggi untuk 'Hujan' diprioritaskan karena ini berarti ketika model memprediksi akan hujan, prediksinya cenderung benar, sehingga dapat meminimalkan risiko penghentian irigasi yang tidak perlu. Sebaliknya, *recall* yang sangat tinggi untuk 'Tidak Hujan' menunjukkan model sangat andal dalam mengidentifikasi kondisi kering, memastikan tanaman tidak akan kekurangan air saat cuaca cerah.

2. Evaluasi Model Penentu Durasi Irigasi (Regresi)

Untuk mendapatkan model penentu durasi pompa yang paling akurat dan andal, dilakukan serangkaian eksperimen dengan melakukan *tuning* pada *hyperparameter* model *Random Forest Regressor*. Beberapa konfigurasi parameter yang berbeda diuji untuk mengevaluasi dampaknya terhadap kinerja model. Hal ini dapat dilihat pada tabel 5.

Tabel 5
(Konfigurasi Percobaan Model Regresi Durasi Pompa)

No	n_estimators	max_depth	min_samples_split	min_samples_leaf
1	100	none	2	1
2	200	8	6	1
3	250	12	2	2
4	300	16	2	1

Pada Tabel 5 menunjukkan beberapa kombinasi *hyperparameter* yang diuji dalam penelitian, termasuk variasi pada n_estimators, min_samples_split, min_samples_leaf, dan max_depth. Setiap konfigurasi ini menghasilkan model dengan karakteristik kinerja yang berbeda. Hasil dari serangkaian percobaan ini menunjukkan adanya peningkatan

performa yang signifikan seiring dengan penyesuaian *hyperparameter*.

Analisis dari empat percobaan utama menunjukkan bahwa konfigurasi awal menghasilkan model dengan *Mean Squared Error* (MSE) yang cukup tinggi sebesar 176.84 detik² dan menunjukkan tanda-tanda *overfitting* karena deviasi standar yang tinggi pada hasil *cross-validation*. Melalui penyesuaian *hyperparameter*, model pada percobaan kedua menunjukkan perbaikan besar dengan MSE yang turun drastis menjadi 56.52 detik² dan stabilitas yang jauh lebih baik. Peningkatan lebih lanjut dicapai pada percobaan ketiga, yang menghasilkan R² Score sebesar 0.88 dengan MSE 49.03 detik², menjadikannya kandidat model yang sangat baik. Akhirnya, konfigurasi pada percobaan keempat terbukti menjadi yang paling optimal. Model ini berhasil mencapai kinerja terbaik dengan R² Score tertinggi sebesar 0.89 dan MSE terendah yaitu 43.72 detik². Hasil ini mengindikasikan bahwa model tersebut adalah yang paling akurat, dengan rata-rata kesalahan prediksi hanya sekitar 6.6 detik, dan memiliki kemampuan generalisasi yang andal. Hal tersebut dapat dilihat pada tabel 6.


Tabel 6
(Evaluasi Data Percobaan)

No	MSE	R ² Score	Stabilitas (deviasi standar R ²)	Keterangan
1	176.84 detik ²	0.79	Rendah (+/- 0.12)	Overfitting
2	56.52 detik ²	0.78	Sangat Tinggi (+/- 0.03)	Stabil
3	49.03 detik ²	0.88	Tinggi (+/- 0.06)	Cukup Bagus
4	43.72 detik ²	0.89	Tinggi (+/- 0.06)	Terbaik

Tabel di atas merangkum perbandingan hasil dari keempat model yang diuji. Berdasarkan metrik evaluasi, konfigurasi nomor 4 secara jelas menunjukkan keunggulan dengan nilai MSE yang paling rendah dan R² Score yang paling tinggi. Stabilitasnya yang tinggi, ditunjukkan oleh deviasi standar yang relatif rendah pada hasil *cross-validation*, juga mengonfirmasi bahwa model ini tidak hanya akurat pada data uji tetapi juga konsisten. Oleh karena itu, model dengan konfigurasi inilah yang dipilih untuk diimplementasikan pada sistem irigasi presisi karena kemampuannya dalam memprediksi durasi pompa secara akurat dan stabil berdasarkan parameter lingkungan yang ada.

C. Analisis Implementasi dan Pembahasan Sistem

Setelah mendapatkan model terbaik dari hasil pelatihan, sistem irigasi presisi diimplementasikan dan diuji dalam kondisi nyata. Analisis dilakukan dengan memeriksa tren data sensor, durasi pompa yang diprediksi model, dan total volume air yang digunakan untuk memberikan gambaran komprehensif tentang kinerja dan efisiensi sistem. Pada gambar 8 menunjukkan grafik histori dari data sensor.




Gambar 8
(Grafik Histori Data Sensor)

Grafik di atas menampilkan histori data sensor lingkungan selama periode pengamatan. Plot pertama menunjukkan persentase kelembaban tanah rata-rata harian, yang terlihat mengalami fluktuasi signifikan sebagai respons terhadap proses irigasi. Terjadi peningkatan dari sekitar 30% hingga mencapai puncaknya di 70% pada 19 Juli pagi, yang kemudian diikuti tren penurunan. Plot kedua menunjukkan suhu udara yang relatif stabil di sekitar 30°C dan kelembaban udara yang berfluktuasi antara 40% hingga 50%. Dinamika pada kelembaban tanah dan udara ini menjadi input penting bagi model untuk menentukan kebutuhan irigasi.



Gambar 9
(Grafik Histori Durasi Pompa)

Pada gambar 9 menunjukkan grafik yang mengilustrasikan bagaimana model regresi secara dinamis menentukan durasi aktif pompa. Terlihat durasi penyiraman bervariasi, dari yang terendah sekitar 23 detik hingga mencapai puncaknya di atas 45 detik pada 18 Juli. Peningkatan durasi ini merupakan respons cerdas model terhadap penurunan tingkat kelembaban tanah yang terdeteksi sensor. Adanya fluktuasi durasi dari hari ke hari membuktikan kemampuan model untuk beradaptasi secara *real-time* terhadap perubahan kondisi lingkungan yang terus-menerus.



Gambar 10
(Grafik Volume Air Harian)

Pada gambar 10 menunjukkan total volume air yang dipompa setiap hari dan menjadi bukti paling kuat dari efisiensi sistem.

Pada 18 Juli, saat tanaman terdeteksi membutuhkan lebih banyak air, sistem memompa lebih dari 20 liter. Hal yang paling signifikan terjadi pada 19 Juli, di mana sistem tidak memompa air sama sekali (0 Liter) karena model menilai kelembaban tanah masih cukup tinggi dari irigasi intensif hari sebelumnya. Ini menunjukkan penghematan air sebesar 100% dibandingkan metode manual yang umumnya tetap menyiram sekitar 20 liter per hari. Pada hari-hari berikutnya, volume yang digunakan jauh lebih rendah, yaitu sekitar 7 liter dan 3.5 liter, membuktikan bahwa sistem secara cerdas mengurangi penyiraman seiring stabilnya kondisi tanah.

Secara keseluruhan, pembahasan ini menunjukkan bahwa sistem irigasi presisi yang dikembangkan jauh lebih unggul daripada metode konvensional. Sistem mampu mengalokasikan air secara dinamis berdasarkan kebutuhan aktual tanaman yang diolah dari data sensor. Dengan memberikan jumlah air yang tepat pada waktu yang tepat, sistem ini berhasil mengurangi pemborosan air secara signifikan sekaligus memastikan kesehatan tanaman.

V. KESIMPULAN

- [1] Safitri Mildawani, "SISTEM IRIGASI CERDAS MENINGKATKAN EFISIENSI AIR DALAM PERTANIAN," *Tugas Mahasiswa Fakultas Pertanian*, vol. 1, no. 1, Mar. 2024, [Online]. Available: <https://coursework.uma.ac.id/index.php/pertanian/article/view/917>
- [2] N. K. Nguyen *et al.*, "Long-term changes in soil biological activity and other properties of raised beds in Longan orchards," *PeerJ*, vol. 12, p. e18396, Nov. 2024, doi: 10.7717/peerj.18396.
- [3] A. Abrar and T. Tukino, "Pengembangan Sistem Pengontrolan Irigasi Cerdas dengan Teknologi Internet of Things (IoT)," *Prosiding Seminar Nasional Ilmu Sosial dan Teknologi (SNISTEK)*, vol. 5, pp. 286–293, Sep. 2023, doi: 10.33884/psnistek.v5i.8096.
- [4] A. A. Abdelmoneim, R. Khadra, A. Elkamouh, B. Derardja, and G. Dragonetti, "Towards Affordable Precision Irrigation: An Experimental Comparison of Weather-Based and Soil Water Potential-Based Irrigation Using Low-Cost IoT-Tensiometers on Drip Irrigated Lettuce," *Sustainability*, vol. 16, no. 1, 2024, doi: 10.3390/su16010306.
- [5] DQLab and Gifa Delyani Nursyafitri, "4 Manfaat Machine Learning, Diketahui Oleh Praktisi Data," <https://dqlab.id/4-manfaat-machine-learning-diketahui-oleh-praktisi-data>.
- [6] J. Xu, Y. Cui, S. Zhang, and M. Zhang, "The evolution of precision agriculture and food safety: a bibliometric study," *Front Sustain Food Syst*, vol. Volume 8-2024, 2024, doi: 10.3389/fsufs.2024.1475602.
- [7] Y. K. Kushwaha, A. Joshi, R. K. Panigrahi, and A. Pandey, "Development of a smart irrigation monitoring system employing the wireless sensor network for agricultural water management," *Journal of Hydroinformatics*, vol. 26, no. 12, pp. 3224–3243, Dec. 2024, doi: 10.2166/hydro.2024.241.

- [8] A. Ariawan, "Smart Sprout: Irigasi Cerdas Berbasis AIoT untuk Pertanian Modern dan Ramah Lingkungan," *bit-Tech*, vol. 7, no. 2, pp. 434–444, Dec. 2024, doi: 10.32877/bt.v7i2.1841.
- [9] Y. Tace, M. Tabaa, S. Elfilali, C. Leghris, H. Bensag, and E. Renault, "Smart irrigation system based on IoT and machine learning," *Energy Reports*, vol. 8, pp. 1025–1036, 2022, doi: <https://doi.org/10.1016/j.egyr.2022.07.088>.
- [10] M. Artiyasa, I. Himawan Kusumah, A. Suryana, A. D. W. Muhammad Sidik, and A. Pradiftha Junfithrana, "Comparative Study of Internet of Things (IoT) Platform for Smart Home Lighting Control Using NodeMCU with Thingspeak and Blynk Web Applications," *https://doi.org/10.52005/fidelity.v2i1.103*, vol. 2, Jan. 2020.
- [11] D. Chen, Z. Wan, D. S. Ha, and J.-H. Cho, "Sustainable Smart Farm Networks: Enhancing Resilience and Efficiency with Decision Theory-Guided Deep Reinforcement Learning," May 2025, [Online]. Available: <http://arxiv.org/abs/2505.03721>
- [12] R. Torhino and P. Andono, "Penerapan Algoritma Random Forest dalam Prediksi Curah Hujan untuk Mendukung Analisis Cuaca," *Building of Informatics, Technology and Science (BITS)*, vol. 6, no. 3, pp. 1688–1699, Dec. 2024, doi: 10.47065/bits.v6i3.6404.
- [13] E. Permana Yudha, A. Rohmadi, and A. T. Setyadi, "SISTEM PREDIKSI PRODUKSI PADI DI SUMATERA MENGGUNAKAN REGRESI LINEAR," *Jurnal Manajemen Informatika & Sistem Informasi (MISI)*, vol. 8, no. 1, 2025, doi: 10.36595/misi.v5i2.
- [14] H. Basri, "Implementasi Sistem Irigasi Cerdas Berbasis IoT dan Machine Learning pada Pembibitan Pala di Papua Barat."