

## IMPLEMENTASI MACHINE LEARNING UNTUK SISTEM IRIGASI CERDAS

Oleh: Raditya Artha Rochmanto<sup>1\*</sup>, Septiantar Tebe Nursaputro<sup>2</sup>

<sup>1,2</sup>Program Studi Teknologi Rekayasa Elektronika, Jurusan Teknik Elektro, Politeknik Negeri Semarang, Semarang, Indonesia

<sup>1,2</sup>Program Studi Teknik Elektronika, Jurusan Teknik Elektro, Politeknik Negeri Semarang, Semarang, Indonesia  
E-mail: [raditya.artha@polines.ac.id](mailto:raditya.artha@polines.ac.id)

### Abstrak

*Penggunaan air yang tidak efisien dalam pertanian seringkali menjadi salah satu penyebab utama menurunnya produktivitas lahan. Di era pertanian modern, implementasi Machine Learning (ML) dapat menjadi solusi untuk memantau kondisi tanah dan menentukan kebutuhan irigasi secara otomatis. Penelitian ini mengembangkan sistem berbasis sensor tanah dengan parameter kelembaban, suhu, cahaya, dan curah hujan yang diproses menggunakan algoritma Random Forest. Data dikembangkan melalui simulasi sebanyak 10.000 sampel tanpa penambahan noise untuk menjaga representasi kondisi nyata. Model Random Forest dibandingkan dengan Decision Tree, SVM, dan Neural Network. Hasil pengujian menunjukkan bahwa Random Forest memberikan performa terbaik dengan akurasi di atas 96,4%. Selain itu dilakukan juga perbandingan penggunaan antara baseline data dengan jumlah data tiap kelas yang berbeda jauh dengan metode penyeimbang data Synthetic Minority Oversampling Technique (SMOTE). Hasil pengujian menunjukkan meskipun penggunaan metode SMOTE menurunkan akurasi secara umum, tetapi dapat meningkatkan Recall yang menunjukkan bahwa model lebih sensitif pada data minoritas.*

**Kata kunci:** irigasi, machine learning, random forest

### Abstract

*Inefficient water use in agriculture is often a major cause of declining land productivity. In the modern agricultural era, the implementation of Machine Learning (ML) can be a solution for monitoring soil conditions and automatically determining irrigation needs. This study developed a soil sensor-based system with parameters of humidity, temperature, light, and rainfall processed using the Random Forest algorithm. Data was developed through simulations of 10,000 samples without the addition of noise to maintain the representation of real conditions. The Random Forest model was compared with Decision Tree, SVM, and Neural Network. The test results showed that Random Forest provided the best performance with an accuracy above 96.4%. Furthermore, a comparison was conducted between the use of baseline data with a significantly different number of data per class using the Synthetic Minority Oversampling Technique (SMOTE) data balancing method. The test results showed that although the use of the SMOTE method decreased accuracy in general, it could increase Recall, making the model more sensitive to minority data.*

**Keywords:** irrigation, machine learning, random forest

### 1. Pendahuluan

Pertanian merupakan sektor yang sangat bergantung pada ketersediaan air. Menurut Food and Agriculture Organization (FAO), sekitar 70% pemanfaatan air tawar global digunakan untuk keperluan irigasi pertanian. Namun, sebagian besar sistem irigasi di negara berkembang masih mengandalkan metode manual atau berbasis jadwal tetap, yang berpotensi menyebabkan pemborosan air dan penurunan produktivitas tanaman. Kondisi ini semakin diperburuk oleh perubahan iklim yang mengakibatkan pola curah hujan tidak menentu, sehingga efisiensi penggunaan air menjadi salah satu isu strategis yang harus dipecahkan.

Di Indonesia, permasalahan irigasi juga cukup

signifikan. Sistem irigasi tradisional tidak mampu menyesuaikan diri dengan kebutuhan tanaman yang dinamis, padahal setiap tanaman memiliki fase pertumbuhan dengan kebutuhan air yang berbeda-beda. Oleh karena itu, diperlukan solusi berbasis teknologi yang mampu memantau kondisi tanah secara real-time sekaligus memprediksi kebutuhan air secara cerdas.

Internet of Things (IoT) menawarkan peluang besar dalam bidang pertanian modern (modern agricultur). Dengan menggunakan sensor kelembaban tanah, suhu, cahaya, dan curah hujan, sistem IoT dapat memberikan data kontinu yang merepresentasikan kondisi lingkungan secara akurat. Namun, data sensor ini bersifat kompleks dan tidak selalu mudah diinterpretasikan secara

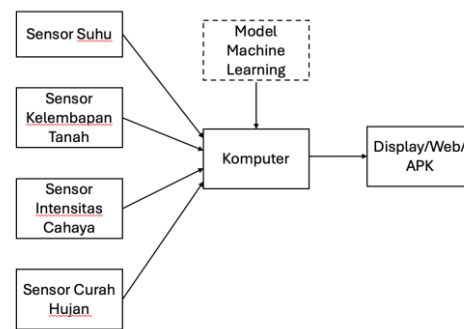
langsung. Oleh karena itu, dibutuhkan integrasi dengan teknologi Machine Learning (ML) yang mampu mengolah data dalam jumlah besar, mengenali pola, dan menghasilkan prediksi yang adaptif.

Beberapa penelitian terdahulu telah mengembangkan sistem monitoring kelembaban tanah berbasis IoT, misalnya tentang perancangan sistem irigasi otomatis berbasis sensor dengan threshold tertentu. Namun, pendekatan berbasis aturan tetap (rule-based system) sering kali kurang fleksibel dalam menghadapi kondisi lingkungan yang dinamis. Sementara itu, penelitian lain mulai mengintegrasikan ML dalam prediksi kebutuhan irigasi.

Berdasarkan gap penelitian tersebut, penelitian ini mengusulkan integrasi Machine Learning (ML) yang dijalankan pada sistem irigasi cerdas dengan data dari multi sensor. Tujuan utama dari penelitian ini adalah mengembangkan sistem monitoring tanah berbasis ML untuk memprediksi kebutuhan irigasi tanaman dalam tiga kategori: tidak butuh air, butuh sedikit air, dan butuh banyak air. Kontribusi penelitian ini meliputi: (1) pengembangan dataset simulasi realistis berbasis parameter lingkungan, (2) evaluasi perbandingan beberapa algoritma ML untuk prediksi kebutuhan irigasi, (3) pengaruh metode penyeimbang jumlah data pada akurasi model.

**2. Metode Penelitian**

Penelitian ini dirancang melalui beberapa tahapan yang melibatkan perancangan arsitektur sistem, pembuatan dataset simulasi, pemilihan algoritma machine learning, proses pelatihan dan evaluasi model. Arsitektur sistem yang dikembangkan terdiri dari tiga lapisan utama. Lapisan pertama adalah perangkat yang bertugas membaca kondisi lingkungan. Pada tahap ini digunakan data dari sensor kelembaban tanah, sensor suhu, sensor intensitas cahaya, serta sensor curah hujan sederhana. Semua data dikirim ke komputer yang berperan sebagai pusat pengolah data. Blok Diagram Sistem ditunjukkan pada Gambar 1.



Gambar 1. Diagram Blok Sistem

Lapisan kedua adalah lapisan machine learning. Data hasil pembacaan sensor dimanfaatkan untuk melatih sebuah model klasifikasi yang bertugas menentukan kebutuhan irigasi tanaman. Untuk keperluan penelitian ini, data sintetis digunakan agar mencerminkan kondisi pertanian tropis dengan variasi kelembaban tanah (10–60%), suhu (20–40 °C), intensitas cahaya (200–1000 lux), dan curah hujan (0–20 mm). Total 10.000 data dihasilkan secara acak dalam rentang nilai realistis. Label kelas ditentukan menggunakan aturan logika yang meniru pengambilan keputusan petani, misalnya tanaman dianggap tidak membutuhkan air jika kelembaban tanah tinggi atau curah hujan memadai, membutuhkan sedikit air jika kondisi tanah moderat dengan suhu dan cahaya normal, serta membutuhkan banyak air apabila tanah kering dengan suhu tinggi atau cahaya berlebih. Jadi label yang digunakan terdiri dari tiga kelas yaitu Kelas 0 (tidak butuh air), Kelas 1 (butuh sedikit air), dan Kelas 2 (butuh banyak air). Hasil pelabelan menghasilkan jumlah data sebagai berikut:

- Kelas 0 (tidak butuh air) : 9132
- Kelas 1 (butuh sedikit air) : 259
- Kelas 2 (butuh banyak air) : 609

Selain itu, pada dataset juga akan disisipkan noise sebanyak 5% dari keseluruhan data. Noise ini membuat sebagian kecil data akan sengaja dibuat salah label (random), sesuai dengan kondisi nyata di lapangan dikarenakan sensor error atau variasi kondisi lapangan.


Pada tahap pemodelan, empat algoritma machine learning diuji untuk mendapatkan perbandingan performa, yaitu Decision Tree, Random Forest, Support Vector Machine (SVM), dan Neural Network berbasis Multi-Layer

Perceptron (MLP). Masing-masing algoritma dipilih karena memiliki karakteristik yang berbeda. Decision Tree menawarkan interpretabilitas, tetapi seringkali mengalami overfitting. Random Forest, yang merupakan penggabungan banyak Decision Tree, memberikan kestabilan lebih baik dan cenderung lebih akurat pada data non-linear. Sementara itu, SVM cocok digunakan untuk data dengan batas kelas kompleks, meskipun sensitif terhadap distribusi data yang tidak seimbang. Neural Network digunakan karena kemampuannya memodelkan hubungan non-linear yang kompleks, meskipun membutuhkan sumber daya komputasi lebih besar.

Tahap pelatihan model dilakukan dengan membagi data menjadi data latih dan data uji menggunakan teknik *stratified split* dengan proporsi 80:20, sehingga distribusi kelas tetap terjaga pada kedua subset data. Jumlah data tiap Kelas pada data latih yaitu:

- Kelas 0 (Tidak butuh air) : 7306
- Kelas 1 (Butuh sedikit air) : 207
- Kelas 2 (Butuh banyak air): 487

Semua fitur dinormalisasi dengan *StandardScaler* agar berada pada skala yang seragam. Jumlah data pada tiap Kelas menunjukkan jumlah yang tidak seimbang, sehingga dilakukan penyeimbangan data dengan metode Synthetic Minority Oversampling Technique (SMOTE). Hasil penyeimbangan ini membuat jumlah data menjadi seimbang yaitu 7306 data pada tiap kelas. Perbandingan distribusi Kelas sebelum dan sesudah penggunaan SMOTE terlihat pada gambar 2.



Gambar 2. Distribusi kelas sebelum dan sesudah SMOTE

Evaluasi model pada penelitian ini tidak hanya menggunakan akurasi, tetapi juga melibatkan precision, recall, F1-score, serta confusion matrix untuk memahami performa klasifikasi pada tiap kelas. Penelitian ini juga membandingkan performa model pada dua kondisi, yakni baseline dengan data tidak seimbang, serta data yang telah diseimbangkan menggunakan metode SMOTE.

### 3. Hasil dan Pembahasan

Penelitian ini menguji performa model machine learning untuk memprediksi kebutuhan irigasi berbasis data multi sensor. Proses pelatihan dilakukan menggunakan dataset simulasi berjumlah 10.000 sampel dengan empat parameter utama, yaitu kelembaban tanah, suhu, intensitas cahaya, dan curah hujan. Setelah melalui tahap pelabelan, diperoleh distribusi kelas yang tidak seimbang, di mana mayoritas data termasuk ke kategori "tidak membutuhkan air", sementara kelas "butuh sedikit air" dan "butuh banyak air" memiliki jumlah sampel jauh lebih kecil. Kondisi ini secara umum mencerminkan situasi nyata di lapangan, di mana sebagian besar kondisi lahan berada dalam keadaan normal, sedangkan kondisi ekstrem relatif jarang terjadi.

Tabel 1. Hasil Perbandingan Performa Model

No	Model	Akurasi	Presisi	Recall	F1-score
1	Decision Tree	0.947	0.671	0.655	0.662
2	Random Forest	0.964	0.940	0.659	0.733
3	SVM	0.943	0.628	0.505	0.545
4	Neural Network	0.960	0.925	0.647	0.720

Tabel 1 menunjukkan Hasil perbandingan performa model pada data baseline atau tidak seimbang. Evaluasi awal terhadap empat algoritma menunjukkan bahwa Random Forest memberikan performa terbaik dengan akurasi di atas 96% pada kondisi baseline (imbalanced data). Decision Tree, SVM, dan Neural Network juga menunjukkan performa yang baik, tetapi cenderung mengalami penurunan presisi pada kelas minoritas. Hal ini ditunjukkan oleh nilai recall dan F1-score yang

rendah, terutama pada kategori "butuh sedikit air". Dengan demikian, dapat dikatakan bahwa meskipun akurasi keseluruhan tinggi, model masih memiliki keterbatasan dalam mengenali kondisi yang jarang terjadi. Padahal kondisi yang jarang terjadi seperti “butuh sedikit air” dan “butuh banyak air” merupakan kondisi yang penting pada irigasi. Jika model gagal mendeteksi kondisi ini maka tanah akan kering karena tidak adanya air yang dialirkan ke tanah.

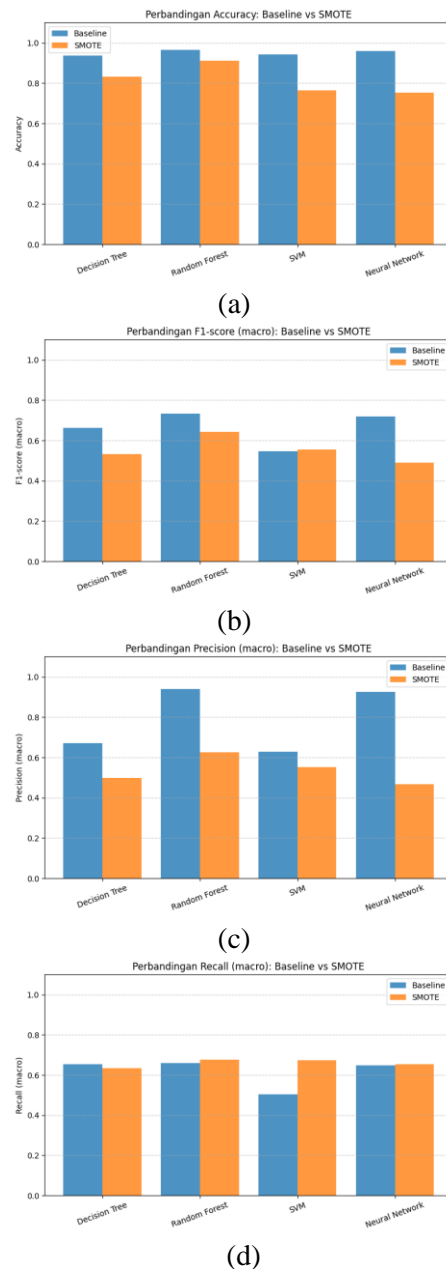
Untuk mengatasi masalah ini, digunakan teknik Synthetic Minority Oversampling Technique (SMOTE) yang menyeimbangkan distribusi kelas dengan cara menghasilkan sampel sintesis pada kelas minoritas.

**Tabel 2.** Hasil Perbandingan Performa Model dengan SMOTE

No	Model	Akurasi	Presi si	Recall	F1-score
1	Decision Tree	0.831	0.498	0.634	0.532
2	Random Forest	0.911	0.626	0.675	0.642
3	SVM	0.765	0.553	0.675	0.554
4	Neural Network	0.753	0.467	0.653	0.489


Tabel 2 menunjukkan hasil perbandingan performa model setelah dilakukan penyeimbangan data menggunakan metode SMOTE. Hasil evaluasi setelah penerapan SMOTE menunjukkan adanya peningkatan recall pada kelas minoritas, meskipun secara keseluruhan akurasi model sedikit menurun. Hal ini sejalan dengan karakteristik SMOTE yang memang berfokus pada perbaikan keseimbangan antar kelas ketimbang mengejar akurasi global. Random Forest tetap konsisten menjadi model dengan kinerja paling stabil, baik pada kondisi baseline maupun setelah balancing, sehingga memperkuat alasan pemilihannya sebagai kandidat utama untuk diimplementasikan. Perbandingan performa antara baseline dengan SMOTE pada masing-masing evaluasi ditunjukkan pada gambar 3.

Selain evaluasi kuantitatif, dilakukan pula analisis confusion matrix untuk melihat performa



Gambar 3. Grafik perbandingan baseline dengan SMOTE pada pengukuran (a) Akurasi, (b) F1-score, (c) Presisi, and (d) Recall

model dalam memprediksi tiap kelas, ditunjukkan pada Gambar 4. Pada Random Forest, sebagian besar kesalahan prediksi terjadi pada kebingungan antara kelas "butuh sedikit air" dan "butuh banyak air". Hal ini disebabkan dalam kondisi sebenarnya perbedaan kebutuhan air antara dua kelas tersebut memang relatif tipis dan sangat dipengaruhi oleh variabilitas suhu maupun intensitas cahaya. Meskipun demikian, tingkat kesalahan masih



Gambar 4. Perbandingan Confusion Matrix model Random Forest pada (a) Baseline data, (b) SMOTE

tergolong kecil dan tidak mengurangi reliabilitas sistem secara keseluruhan. Pada confusion matrix juga terlihat jumlah prediksi yang sesuai dengan kondisi aktual pada kelas-kelas minoritas. Hasil ini membuktikan penggunaan SMOTE membuat model menjadi lebih sensitif pada Kelas dengan jumlah minoritas.

Secara keseluruhan, penelitian ini menunjukkan bahwa integrasi machine learning menawarkan solusi praktis untuk mendukung pertanian modern yang bekerja secara otomatis. Random Forest terbukti memberikan kombinasi terbaik antara akurasi, stabilitas, dan efisiensi komputasi. Hal ini menjadikan penelitian ini sebagai salah satu langkah nyata dalam mewujudkan sistem irigasi cerdas yang hemat air, murah, dan dapat diterapkan pada berbagai kondisi pertanian di Indonesia.

#### 4. Kesimpulan

Penelitian ini membuktikan bahwa implementasi Machine Learning dapat meningkatkan efisiensi sistem irigasi pertanian. Random Forest terbukti sebagai algoritma terbaik dengan akurasi di atas 96%, lebih stabil dibandingkan algoritma lain. Penggunaan SMOTE memberikan trade-off antara akurasi global dan sensitivitas terhadap kelas minoritas.

Implementasi pada ESP32 menunjukkan

bahwa embedded machine learning memungkinkan penerapan sistem irigasi cerdas secara langsung di lapangan tanpa ketergantungan server. Penelitian ini memberikan kontribusi nyata pada pengembangan smart farming, dan penelitian lanjutan dapat diarahkan pada uji coba dengan data sensor nyata di lahan pertanian.

#### DAFTAR PUSTAKA

- M. Camporese, S. J. Gumière, M. Putti, and G. Botter, “Efficient Irrigation of Maize Through Soil Moisture Monitoring and Modeling,” *Frontiers in Water*, vol. 3, Mar. 2021, doi: 10.3389/frwa.2021.627551.
- M. L. Page, L. Jarlan, M. E. Hajj, M. Zribi, N. Baghdadi, and A. Boone, “Potential for the Detection of Irrigation Events on Maize Plots Using Sentinel-1 Soil Moisture Products,” *Remote Sensing*, vol. 12, no. 10, p. 1621, May 2020, doi: 10.3390/rs12101621.
- S. Taghvaeian et al., “Irrigation Scheduling for Agriculture in the United States: The Progress Made and the Path Forward,” *Transactions of the ASABE*, vol. 63, no. 5, p. 1603, Jan. 2020, doi: 10.13031/trans.14110.
- M. B. Budiarto, A. Supriadi, S. Hidayat, and S. Salehudin, “Model Irigasi Hemat Air Perpaduan System of Rice Intensification (SRI) dengan Alternate Wetting and Drying (AWD) pada Padi Sawah,” *Jurnal Teknik Pengairan*, vol. 11, no. 2, p. 128, Nov. 2020, doi: 10.21776/ub.pengairan.2020.011.02.06.
- M. F. Saputra and R. R. Suryono, “Implementasi Teknologi Irigasi Tetes pada Tanaman Jagung Menggunakan Sensor Soil Moisture dan Mikrokontroler Esp 32,” *MALCOM Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 1, p. 111, Dec. 2024, doi: 10.57152/malcom.v5i1.1642.
- N. C. Gäitan, B. I. Batinas, C. Ursu, and F. N. Crainiciuc, “Integrating Artificial Intelligence into an Automated Irrigation System,” *Sensors*,

vol. 25, no. 4, p. 1199, Feb. 2025, doi: 10.3390/s25041199.

10.22236/teknoka.v5i.297.

- A. A. Abdelmoneim, H. N. Kimaita, C. M. A. Kalaany, B. Derardja, G. Dragonetti, and R. Khadra, "IoT Sensing for Advanced Irrigation Management: A Systematic Review of Trends, Challenges, and Future Prospects," *Sensors*, vol. 25, no. 7. Multidisciplinary Digital Publishing Institute, p. 2291, Apr. 04, 2025. doi: 10.3390/s25072291.
- Md. A. K. Akhtar et al., "Smart Irrigation for Sustainable Farming: Low- Cost IoT Solution," *Research Square* (Research Square), Aug. 2024, doi: 10.21203/rs.3.rs-4720649/v1.
- E. Avşar and Md. N. Mowla, "Wireless communication protocols in smart agriculture: A review on applications, challenges and future trends," *Ad Hoc Networks*, vol. 136. Elsevier BV, p. 102982, Aug. 27, 2022. doi: 10.1016/j.adhoc.2022.102982.
- D. Weraikat, K. Šorić, M. Žagar, and M. Sokač, "Data Analytics in Agriculture: Enhancing Decision-Making for Crop Yield Optimization and Sustainable Practices," *Sustainability*, vol. 16, no. 17, p. 7331, Aug. 2024, doi: 10.3390/su16177331.
- T. Miller et al., "Integrating Artificial Intelligence Agents with the Internet of Things for Enhanced Environmental Monitoring: Applications in Water Quality and Climate Data," *Electronics*, vol. 14, no. 4, p. 696, Feb. 2025, doi: 10.3390/electronics14040696.
- G. Santoso, S. Hani, and R. Prasetyo, "Sistem Monitoring Kualitas Tanah Tanaman Padi dengan Parameter Suhu dan Kelembaban Tanah Berbasis Internet of Things (IoT)," *Prosiding Seminar Nasional Teknoka*, vol. 5, p. 146, Dec. 2020, doi: 10.22236/teknoka.v5i.297.
- A. SURYANINGRAT, D. Kurnianto, and R. A. Rochmanto, "Sistem Monitoring Kelembaban Tanaman Cabai Rawit menggunakan Irigasi Tetes Gravitasi berbasis Internet Of Things (IoT)," *ELKOMIKA Jurnal Teknik Energi Elektrik Teknik Telekomunikasi & Teknik Elektronika*, vol. 10, no. 3, p. 568, Jul. 2022, doi: 10.26760/elkomika.v10i3.568.
- N. Hassan, S. H. Cheragee, S. Ahammed, and A. Z. Md. T. Islam, "Sensor based Smart Irrigation System with Monitoring and Controlling using Internet of Things," *The International Journal of Ambient Systems and Applications*, vol. 9, no. 2, p. 17, Jun. 2021, doi: 10.5121/ijasa.2021.9203.
- R. Matenge., "SOIL MOISTURE BASED IRRIGATION TEST IN A REMOTELY MONITORED AUTOMATED SYSTEM.," *International Journal of Advanced Research*, vol. 5, no. 12, p. 15, Dec. 2017, doi: 10.21474/ijar01/5932.
- G. S. P. Lakshmi, P. N. Asha, G. Sandhya, S. Sharma, S. Shilpashree, and S. G. Subramanya, "An intelligent IOT sensor coupled precision irrigation model for agriculture," *Measurement Sensors*, vol. 25, p. 100608, Dec. 2022, doi: 10.1016/j.measen.2022.1006