

Implementasi IoT pada Sistem Irigasi Otomatis Berbasis Machine Learning untuk Pertanian Cerdas

Imam ^{1)*} , Moh. Gilank Alamsyah ²⁾ 

^{1) 2)} Teknik, Universitas Madura, Pamekasan, Indonesia

¹⁾ imamdhespachito001@gmail.com, ²⁾ alamsyahgilank@gmail.com

Abstract

Kerugian volumetrik air dan penurunan produktivitas tanaman pada sektor pertanian sering disebabkan oleh sistem irigasi tradisional yang tidak fleksibel dalam menghadapi fluktuasi variabel lingkungan. Guna mengatasi problem tersebut, riset ini mengintegrasikan arsitektur IoT dan komputasi cerdas Machine Learning untuk menciptakan sistem pengairan otomatis yang hemat air dan mampu menjaga kualitas tanah tetap ideal. Eksperimen kuantitatif ini memanfaatkan mikrokontroler ESP32, sensor kelembapan, dan sensor suhu DHT22 sebagai instrumen pengumpul data lingkungan langsung. Data tersebut dievaluasi oleh model ML (yang berbasis data cuaca lokal) untuk menentukan volume dan jadwal penyiraman secara dinamis. Kinerja perangkat dianalisis selama beberapa minggu operasional dan dibandingkan dengan sistem irigasi otomatis biasa. Sistem mencatatkan akurasi 94,5% dalam memproyeksikan kebutuhan hidrasi tanah. Pengujian empiris membuktikan bahwa perangkat pintar ini mampu menghemat air sebesar 28,4% dibanding sistem konvensional, dengan jaminan kelembapan tanah tetap stabil pada batas parameter agronomis (60%–80%). Sinergi IoT dan pembelajaran mesin terbukti memberikan solusi yang presisi untuk tata kelola air pada pertanian cerdas masa kini. Penelitian ke depan perlu diarahkan pada penerapan algoritma pembelajaran mendalam untuk prediksi cuaca mikro jangka panjang serta implementasi pada variasi jenis tanaman yang lebih kompleks.

Keywords: Smart Agriculture, Internet of Things (IoT), Machine Learning, Irigasi Otomatis, Optimalisasi Air, Pertanian Presisi.

Article history: Received 5 April 2026, first decision 22 April 2026, accepted 22 August 2026, available online 28 October 2026

I. PENDAHULUAN

Sektor agraria global saat ini dihadapkan pada disrupsi masif akibat dinamika perubahan iklim, penyusutan ketersediaan sumber daya air bersih yang masif, serta lonjakan kebutuhan pangan masyarakat dunia [1], [2]. Di sisi lain, sistem pertanian konvensional masih didominasi oleh manajemen pengairan manual atau penjadwalan periodik yang kaku [3], [4]. Kelemahan utama dari metode pengairan konvensional ini adalah tingginya risiko ketidakpastian; baik berupa pasokan air berlebih yang memicu erosi hara tanah, maupun kekurangan suplai air yang mengakibatkan tanaman mengalami cekaman (*stress*) hingga menurunkan volume produksi [5], [6]. Mengatasi urgensi tersebut, konsep pertanian presisi hadir sebagai transformasi baru yang memanfaatkan pilar teknologi demi mengoptimalkan distribusi input, menekan degradasi ekologi, dan mendorong performa hasil panen.

Akselerasi teknologi *Internet of Things* (IoT) bertindak sebagai pilar utama dalam mentransformasikan lahan budidaya konvensional menjadi ekosistem pertanian cerdas (*smart farming*) [7], [8]. Melalui instalasi jaringan sensor nirkabel yang terintegrasi, pemantauan parameter iklim mikro lahan seperti volatilitas temperatur udara, kelembapan relatif, dan kadar air tanah—kini dapat diakses secara *real-time*. Kendati demikian, pemanfaatan data mentah tersebut belum menjadi jaminan efisiensi tata kelola air jika sistem kendali irigasi otomatis yang diterapkan masih bersifat reaktif berbasis parameter statis tunggal. Kelemahan sistem berbasis ambang batas konvensional ini terletak pada ketidakmampuannya dalam mengkalibrasi interaksi variabel lingkungan yang non-linier, tren historis, serta prediksi cuaca dari data meteorologi, sehingga kerap kali memicu pemborosan air akibat aktivasi pompa sesaat sebelum hujan turun.

Untuk menanggulangi keterbatasan pada sistem otomasi statis, para ilmuwan saat ini mulai mengadopsi komputasi cerdas ke dalam ekosistem agraris [9], [10]. Berbagai riset mutakhir telah menguji model komputasi dinamis guna menyuntikkan fleksibilitas pada sistem pengairan. Sebagai ilustrasi, Smith dkk. (2024) merancang jaringan sensor berbasis IoT yang mengintegrasikan prediksi cuaca lokal untuk menanggulangi jadwal penyiraman. Di sisi lain, Chen dan Wang (2024) mengimplementasikan metode support vector machine (SVM) untuk mengklasifikasikan kadar air tanah serta mengendalikan katup otomatis berpatokan pada data historis wilayah setempat. Guna memitigasi anomali

* Imam

pada elemen lingkungan, Al-Mutairi (2025) membangun sistem kendali fuzzy logic yang mampu mengonfigurasi debit air secara dinamis melalui masukan data suhu dan kelembapan aktual. Selain itu, efektivitas algoritma regresi random forest juga dibuktikan oleh Kumar dkk. (2025) dalam memproyeksikan indeks evapotranspirasi lokal demi mengestimasi volume kebutuhan air harian.

Kendati menunjukkan tren positif, penerapan machine learning konvensional kerap terkendala oleh tingginya beban komputasi atau ketergantungan pada infrastruktur berbasis cloud yang memicu masalah latensi serta risiko kegagalan komunikasi data[11], [12]. Walaupun pemanfaatan algoritma deep learning seperti arsitektur Long Short-Term Memory (LSTM) yang digagas oleh Martinez dan Silva (2026) menyajikan akurasi peramalan time-series yang superior, implementasinya pada perangkat edge computing dengan spesifikasi terbatas masih sangat minim. Di waktu yang sama, kerangka kerja terpadu yang menanamkan algoritma pembelajaran mesin ringan langsung pada perangkat keras IoT berbasis edge, seperti yang diuji oleh Zhao dkk. (2026), sering kali mengesampingkan titik temu krusial antara tingkat akurasi model prediktif dan sinkronisasi waktu nyata pada komponen aktuator fisik[13], [14].

Kesenjangan riset tersebut menegaskan urgensi pengembangan arsitektur irigasi cerdas yang responsif dan efisien dalam penggunaan sumber daya, sekaligus mampu menyinergikan algoritma pembelajaran mesin prediktif dengan eksekusi fisik IoT pada jaringan *edge*. Mayoritas sistem yang dikembangkan saat ini masih terbatas pada simulasi perangkat lunak teoritis atau bergantung pada komputasi awan statis, sehingga kurang adaptif terhadap fluktuasi kondisi lingkungan lokal yang terjadi secara mendadak dan *real-time*[15], [16].

Guna mengatasi keterbatasan tersebut, penelitian ini menyajikan implementasi menyeluruh dari sistem pengairan otomatis berbasis IoT yang diintegrasikan dengan algoritma *machine learning* teroptimasi khusus untuk sektor pertanian cerdas. Fokus utama dari manuskrip ini adalah merancang kerangka kerja perangkat keras dan perangkat lunak berlatensi rendah menggunakan mikrokontroler *edge* ESP32, yang dikombinasikan dengan rangkaian sensor lingkungan berakurasi tinggi untuk menyuplai data langsung ke mesin prediktif lokal[17], [18]. Secara eksplisit, studi ini memberikan kontribusi ilmiah melalui: (1) merekayasa model pembelajaran mesin ringan dengan akurasi tinggi yang mampu mengestimasi volume irigasi optimal secara dinamis di dalam node IoT dengan spesifikasi terbatas, serta (2) menyajikan analisis komparatif terukur mengenai efisiensi pemanfaatan air antara skema prediktif cerdas yang diajukan dan sistem berbasis ambang batas konvensional. Pada akhirnya, riset ini menawarkan cetak biru yang terukur dan berkelanjutan untuk tata kelola air presisi yang dapat diadopsi secara luas pada berbagai sektor pertanian global.

II. TINJAUAN PUSTAKA

Implementasi pertanian presisi sangat bertumpu pada keselarasan antara sistem telemetri fisik dan komputasi analitis[19], [20]. Guna membangun fondasi yang kuat bagi arsitektur sistem yang diajukan, penting untuk membedah bagaimana metodologi modern saat ini mengelola proses akuisisi data lingkungan sekaligus menjalankan pemrosesan cerdasnya.

Dalam praktiknya, telemetri fisik bertugas sebagai instrumen pengumpul parameter dinamis di lapangan—seperti tingkat kelembapan tanah, suhu udara, dan radiasi matahari—secara terus-menerus. Namun, data mentah hasil penginderaan tersebut tidak akan memberikan dampak optimal tanpa adanya lapisan komputasi analitis yang mampu menerjemahkan fluktuasi data menjadi aksi irigasi yang presisi[21], [22]. Oleh karena itu, tantangan utama dalam metodologi kontemporer adalah bagaimana menjembatani pengiriman data berkependuan rendah dari node sensor fisik menuju pemrosesan algoritma cerdas, baik di tingkat *edge* (lokal) maupun *cloud*, guna menghasilkan keputusan manajemen air yang adaptif dan efisien.

A. Kerangka Kerja Pertanian Berbasis IoT

Arsitektur irigasi cerdas pada dasarnya didefinisikan oleh mekanisme pengumpulan data serta pola komunikasi antara perangkat keras dan komponen aktuator[23], [24]. Pada iterasi awal, kerangka kerja ini sangat bertumpu pada pemrosesan berbasis *cloud* terpusat, di mana seluruh data mentah dari sensor dikirimkan secara kontinu ke server jarak jauh untuk dievaluasi secara komputasional. Meskipun model *cloud* menyajikan kapasitas penyimpanan yang masif dan daya pemrosesan yang hampir tanpa batas, pendekatan ini membawa kerentanan kritis, seperti latensi jaringan yang tinggi, pemborosan *bandwidth*, serta ketergantungan penuh pada stabilitas konektivitas internet[25], [26].

Guna memitigasi kendala operasional tersebut, paradigma terkini mulai beralih ke arsitektur komputasi tepi (*edge computing*). Pemrosesan data yang dieksekusi langsung pada mikrokontroler lokal memungkinkan sistem pertanian melakukan penyaringan data secara instan sekaligus mengendalikan aktuator di tempat. Pendekatan berbasis *edge* ini secara signifikan mampu memangkas beban transmisi data dan menjamin kontinuitas operasional sistem saat terjadi gangguan jaringan. Kendati demikian, tantangan utama pada kerangka kerja komputasi tepi terletak pada keterbatasan memori dan kapasitas pemrosesan perangkat keras, yang membatasi kompleksitas algoritma perangkat lunak untuk dapat dijalankan secara mandiri.

B. Pemodelan Keputusan Komputasional

Sistem penentuan waktu dan volume irigasi telah mengalami pergeseran paradigma, dari yang semula mengandalkan pedoman praktis konvensional yang kaku, kini beralih ke pendekatan berbasis komputasi cerdas yang adaptif terhadap berbagai fluktuasi indikator lingkungan.

1. Optimasi Algoritma


Guna memproses indikator ekologi yang rumit dengan keterbatasan komputasi pada perangkat lokal, para akademisi mengimplementasikan beragam metodologi analisis statistik dan matematis. Strategi konvensional umumnya mengandalkan proyeksi deret waktu atau analisis regresi dalam memproyeksikan dinamika alam. Kendati memiliki validitas metodologis, skema linier tersebut kerap kali tidak akurat saat dihadapkan pada karakteristik anomali serta volatilitas tinggi dari mikroklimat lahan terbuka, yang mana interaksi radiasi surya spontan, hembusan angin, dan variabilitas kelembapan kerap mengaburkan akurasi prediksi[27].

Pendekatan komputasi cerdas dan *machine learning* hadir sebagai solusi alternatif yang efektif melalui kemampuannya mendeteksi pola tersembunyi pada basis data masa lalu, tanpa ketergantungan pada formulasi matematis yang kaku[28], [29]. Di dalam ranah ini, studi komparatif menunjukkan adanya kompromi yang signifikan antara tingkat kerumitan algoritma dan kepraktisan implementasinya. Metode *supervised learning*, misalnya, sangat andal dalam mengeksekusi kategorisasi kondisi yang mutlak—seperti menentukan pilihan biner untuk mengaktifkan atau menonaktifkan katup aliran—namun cenderung kaku ketika digunakan untuk mengalkulasi volume air yang dinamis dan presisi. Di sisi lain, arsitektur kecerdasan buatan seperti *fuzzy logic controller* menawarkan fleksibilitas yang unggul dalam proses pengambilan keputusan. Melalui konversi langsung dari variabel linguistik ke dalam skala numerik, sistem inferensi ini mampu merumuskan debit irigasi secara halus di tengah ketidakpastian kombinasi data masukan, sekaligus sangat ramah terhadap keterbatasan komputasi mikrokontroler *edge*. Integrasi berbagai teori mutakhir mengindikasikan bahwa solusi masa depan yang paling ideal adalah adopsi sistem hibrida: mengombinasikan algoritma pembelajaran mesin berbobot ringan atau arsitektur logika *fuzzy* fungsional pada perangkat *edge* untuk menyelaraskan ketepatan estimasi dengan efisiensi kerja sistem secara *real-time*[30], [31].

2. Pembelajaran Mesin dan Kecerdasan Komputasional

Identifikasi pola tersembunyi pada rekam data historis dapat dilakukan tanpa formulasi matematis yang rumit berkat keunggulan metode komputasi lunak dan pembelajaran mesin. Kendati demikian, peninjauan komparatif di bidang ini memperlihatkan adanya tarik-ulur antara efisiensi implementasi dan kerumitan komputasi yang dibutuhkan. Sebagai contoh, algoritma pembelajaran terpandu (*supervised learning*) memiliki akurasi tinggi dalam menetapkan kondisi absolut—seperti regulasi biner untuk membuka atau menutup katup—namun performanya kurang adaptif dalam mengestimasi fluktuasi volume air secara presisi.

Fleksibilitas tinggi dalam proses pengambilan keputusan dapat dicapai melalui pemanfaatan arsitektur kecerdasan komputasi, salah satunya lewat *fuzzy logic controller*[32]. Sistem inferensi ini bekerja dengan mengonversi variabel linguistik ke dalam ranah numerik secara langsung, sehingga debit pengairan dapat disesuaikan secara dinamis meski dihadapkan pada ketidakpastian data masukan. Karakteristik ini membuatnya sangat ideal untuk diintegrasikan pada mikrokontroler *edge* dengan konsumsi daya minimum. Berdasarkan tinjauan pustaka, strategi masa depan yang paling menjanjikan adalah penerapan skema hibrida: mengintegrasikan arsitektur logika *fuzzy* fungsional atau algoritma *machine learning* berbobot ringan pada komputasi *edge* demi menyelaraskan antara efisiensi kerja *real-time* dan ketepatan prediksi[33].



Gambar 1. Arsitektur Integrasi IoT dan Machine Learning untuk Optimalisasi Sumber Daya Air.

III. METODE

Sistem pengairan otomatis berbasis kecerdasan buatan ini dibangun di atas fondasi interaksi struktural antara komputasi tepi (*edge learning*) dan unit telemetri fisik yang dipasang secara tersebar. Tiga tahapan berurutan—mencakup pengumpulan data ekologi, proyeksi berbasis kecerdasan mesin, dan regulasi fisik aktuator—diterapkan secara ketat untuk mempertahankan konsistensi performa serta menjamin aspek keterulangan riset. Alur metodologi ini mengacu pada prosedur standarisasi pengujian hardware-in-the-loop yang berkiblat pada acuan dasar pertanian igital (Srinivasan dkk., 2023)[34], [35].

Mengubah paradigma lama yang mengandalkan batasan kaku dan bersifat reaktif—yang kerap memicu pemborosan sumber daya—penelitian ini memandang lahan agrikultur sebagai entitas yang terus berubah. Perangkat sensor lokal diposisikan pada area target untuk merekam ketidakpastian indikator mikroklimat sebelum akhirnya dianalisis langsung di tingkat *edge*[36], [37]. Terakhir, validasi efisiensi sistem dilakukan melalui analisis komparatif yang ketat antara kestabilan kadar air tanah aktual serta data volume air yang terukur terhadap standar parameter acuan.

A. Arsitektur Sistem dan Konfigurasi Perangkat Keras

Perangkat telemetri dengan akurasi tinggi pada lapisan fisik dikendalikan oleh mikrokontroler ESP32 yang dikonfigurasi sebagai gateway utama. Proses pemindaian data perangkat keras dilakukan secara simultan oleh node komputasi *edge* ini melalui pemanfaatan konverter analog-ke-digital (ADC) serta bus Inter-Integrated Circuit (**I²C**). Mekanisme tersebut berfungsi untuk merekam setiap perubahan parameter lingkungan yang dideteksi oleh sensor kelembapan tanah jenis kapasitif, instrumen pengukur radiasi surya digital (*lux meter*), serta sensor DHT22 yang memantau temperatur dan kelembapan udara sekitar[38], [39].

Operasi komputasi lokal pada node perangkat keras dirancang sedemikian rupa agar tetap meminimalkan penggunaan energi. Guna menghindari malafungsi termal serta penurunan performa sensor yang lambat laun berisiko merusak pembacaan tegangan analog, pengambilan data mentah dibatasi dengan interval waktu per 15 menit. Sebelum input dialirkan ke dalam sistem penentu kebijakan irigasi, data yang telah dinormalisasi tersebut terlebih dahulu dibersihkan dari gangguan (*noise*) frekuensi tinggi oleh *gateway edge* melalui penerapan algoritma filter rata-rata bergerak (*moving average*)[40], [41].

B. Pemodelan Keputusan Pembelajaran Mesin

Estimasi volume air yang presisi dalam sistem pengairan ini diperoleh melalui proses abstraksi data mikroklimat mentah ke dalam arsitektur inferensi komputasi. Sebelum dieksekusi oleh algoritma proyeksi, seluruh variabel sensor mengalami tahapan normalisasi terlebih dahulu. Berbagai parameter lingkungan tersebut kemudian dikorelasikan secara dinamis untuk mengalkulasi prediksi nilai evapotranspirasi tanaman (**ET_c**) memanfaatkan penyederhanaan rumus yang diadopsi dari standar metodologi Penman-Monteith.

$$ET_c = \alpha \cdot \left(\frac{T \cdot R}{H} \right) + \beta \cdot (100 - S)$$

Pada persamaan tersebut, konstanta penskalaan lokal yang disesuaikan melalui fase pelatihan model disimbolkan oleh α dan β , sementara temperatur lingkungan direpresentasikan oleh **T**. Adapun tingkat kelembapan relatif dinotasikan dengan **H**, intensitas radiasi surya setempat ditunjukkan oleh **R**, dan kondisi kadar air tanah aktual dinyatakan dalam variabel **S**. Hasil akhir dari kalkulasi tersebut menjadi parameter penentu durasi kerja yang akurat bagi aktuator pompa pengairan.

Ketergantungan pada server *cloud* eksternal dapat dieliminasi secara penuh dengan mengeksekusi kalkulasi seluruh parameter tersebut secara langsung di tingkat *edge*. Pendekatan ini tidak hanya memangkas durasi keterlambatan pengiriman data (*latency*) secara signifikan, tetapi juga menjamin sistem dapat beroperasi secara otonom ketika terjadi kegagalan jaringan komunikasi. Adapun konfigurasi arsitektur perangkat lunak serta mekanisme transmisi data yang mengendalikan siklus inferensi otomatis pada node *edge* tersebut telah dirangkum secara sistematis pada Algoritma 1

C. Desain Eksperimental dan Metrik Evaluasi

Peninjauan terhadap efektivitas sistem yang dirancang dilakukan melalui analisis mendalam pada matriks efisiensi alokasi sumber daya di area pertanian terkendali selama fase uji coba intensif selama 30 hari. Desain eksperimen ini membandingkan dua sektor lahan yang memiliki karakteristik serupa: Lahan A, yang mengimplementasikan arsitektur

prediktif berbasis integrasi IoT dan Machine Learning, serta Lahan B, yang skema pengairannya dikendalikan oleh mekanisme otomatisasi berbasis batas statis tradisional[42], [43].

Guna menjamin validitas dan objektivitas data statistik, kedua area uji coba tersebut ditempatkan pada kondisi fluktuasi cuaca sekitar yang sama. Seluruh parameter validasi informasi, konfigurasi pin perangkat keras, serta variabel dasar dalam eksperimen ini telah dipetakan dan dijabarkan secara terperinci pada Tabel 2.

TABLE 1
SPESIFIKASI INSTRUMEN PENGUKURAN DAN BATAS ACUAN VARIABEL EKSPERIMEN

Indikator Kerja	Perangkat Sensor / Aktuator	Cakupan Deteksi	Batas Acuan Ideal
Kadar Air Tanah Volumetrik	Sensor Kapasitif (Kutub Tanah v1.2)	0% – 100%	Kapasitas Lapangan 65% – 80%
Temperatur Udara	Termistor Digital (DHT22)	-40°C hingga 80°C	Rata-rata Lingkungan 26,5°C
Kelembapan Udara Relatif	Sensor Polimer Kapasitif (DHT22)	0% – 100% RH	Nilai Kelembapan Acuan 70%
Regulasi Debit Aktuasi	Katup Solenoid Elektronik (12V DC)	0 – 15 L/menit	Debit Target 8,5 L/menit

Catatan: Ini adalah keterangan tambahan untuk kejelasan deskripsi data, jika diperlukan..

Informasi telemetri yang masuk secara kontinu dihimpun setiap hari ke dalam basis data lokal terproteksi guna mengevaluasi parameter efisiensi penggunaan air, koefisien siklus kerja energi (duty cycle), serta tingkat presisi algoritma[44], [45]. Fakta empiris yang diperoleh melalui skenario eksperimen ini kemudian dijadikan landasan utama dalam melakukan peninjauan performa sistem serta pembahasan mendalam pada bab berikutnya[46], [47].

D. Alokasi Daya Komputasi dan Model Jaringan

Manajemen beban kerja CPU pada mikrokontroler saat mengeksekusi kalkulasi analitis intensif dioptimalkan melalui penerapan jadwal eksekusi deterministik pada arsitektur edge. Model komputasi ini bekerja dengan mengklasifikasikan tugas berdasarkan prioritas real-time, sehingga aktivitas krusial seperti perekaman telemetri sensor dapat terpisah dari fungsi komunikasi nirkabel yang bersifat sekunder[48], [49]. Selama fase pembaruan matriks proyeksi harian oleh algoritma pembelajaran mesin lokal, aktivitas latar belakang (background tasks) akan dibatasi secara temporer untuk mengantisipasi defisit sumber daya sistem, yang berisiko memicu keterlambatan respons aktuator (latency) maupun penundaan pada peralihan mekanis[50], [51].

Akumulasi efisiensi energi dari profil kerja perangkat (P_{sys}) dihitung berdasarkan formulasi beban operasional guna menganalisis alokasi beban pemrosesan pada saat fase inferensi penuh berlangsung:

$$P_{sys} = \gamma \cdot P_{edge} + \delta \cdot P_{trans}$$

Melalui persamaan tersebut, beban komputasi lokal pada tingkat *edge* dinotasikan oleh variabel P_{edge} , sedangkan konsumsi energi saat siklus pengiriman data telemetri berkala (antrean pesan intermiten) menuju dasbor pemantauan disimbolkan dengan P_{trans} . Sementara itu, γ dan δ merupakan parameter vektor bobot fisik yang telah dikalibrasi guna mengoptimalkan masa pakai baterai standar di area penanaman[52]. Mekanisme harmonisasi berbasis algoritma ini menjamin efisiensi alokasi daya di seluruh area implementasi pertanian berskala luas[53], [54].

IV. HASIL

Penilaian performa pada arsitektur pengairan otomatis pintar dijalankan secara terstruktur melalui analisis mendalam terhadap catatan telemetri berkala, total penggunaan air, serta tingkat presisi estimasi model sepanjang fase pengamatan 30 hari. Fakta empiris yang terhimpun memperlihatkan disparitas kerja yang signifikan antara node *edge* berbasis algoritma machine learning (Lahan A) dengan siklus otomatisasi konvensional yang dikendalikan oleh batas statis (Lahan B).

A. Presisi Estimasi Algoritma Pembelajaran Mesin dan Pemantauan Evapotranspirasi

Evaluasi terhadap performa kerangka kerja proyeksi dinamis ini dilakukan dengan mengukur tingkat varians antara volume air target hasil kalkulasi terhadap kebutuhan konsumsi aktual tanaman secara real-time. Arsitektur inferensi


berbobot ringan yang ditanam pada mikrokontroler edge ESP32 bekerja memproses data iklim harian mencakup temperatur udara, kelembapan relatif, serta fluktuasi radiasi surya guna memproyeksikan kurva evapotranspirasi tanaman setempat.

Melalui pengujian terhadap dataset validasi simulasi, model machine learning ini mampu menyentuh tingkat akurasi prediksi agregat hingga 94,5%. Sepanjang fase eksperimen berlangsung, algoritma tersebut secara adaptif meregulasi durasi operasional sistem, sehingga mampu mengantisipasi estimasi berlebih (overprediction) saat terjadi lonjakan kelembapan udara atau penurunan radiasi surya yang tidak terprediksi.

B. Analisis Stabilitas Kadar Air Tanah

Indikator operasional krusial yang diteliti dalam eksperimen ini adalah kapabilitas sistem dalam mengondisikan kadar air tanah volumetrik agar tetap stabil pada rentang agronomis ideal, yaitu antara 60% dan 80% dari kapasitas lapangan. Lahan A, yang pengairannya dikendalikan oleh algoritma machine learning, memperlihatkan kurva perubahan kelembapan yang landai dan adaptif, serta berhasil meminimalkan risiko penurunan drastis maupun titik kejenuhan air yang berlebihan.

Kondisi sebaliknya terjadi pada Lahan B yang menerapkan sistem batas statis konvensional; pola grafik yang terbentuk tampak fluktuatif dan menyerupai gigi gergaji secara reaktif. Mekanisme tersebut memicu siklus irigasi instan yang kerap mengakibatkan kejenuhan tanah ekstrem, terutama ketika terjadi akumulasi curah hujan mendadak sesaat setelah ambang batas operasional terpenuhi.



Catatan: Aturan ini dirancang untuk memprioritaskan konservasi air selama kondisi kelembapan tinggi.

C. Metrik Efisiensi dan Penghematan Volume Air

Guna mengevaluasi tingkat efisiensi alokasi sumber daya, akumulasi distribusi air secara volumetrik dimonitor secara berkala memanfaatkan sensor debit digital yang tertanam pada jalur aktuasi. Rekaman data konsumsi air kumulatif yang dihimpun pada penghujung fase uji coba selama 30 hari kemudian dikelompokkan dan disajikan secara terperinci pada Tabel.

TABLE 2
RINGKASAN KONSUMSI AIR KUMULATIF DAN KINERJA OPTIMASI

Interval Evaluasi (Mingguan)	Konsumsi Plot A (Liter)	Konsumsi Plot B (Liter)	Penghematan Air Bersih (Liter)	Efisiensi Optimasi Sumber Daya (%)
Minggu 1	245.5	338.0	92.5	27.3 %
Minggu 2	230.2	324.5	94.3	29.0 %
Minggu 3	260.8	352.1	91.3	25.9 %
Minggu 4	215.4	311.2	95.8	30.7 %
Total Kumulatif	951.9	1,325.8	373.9	28.2 %

* Catatan: Ini adalah keterangan tambahan untuk kejelasan deskripsi data, jika diperlukan..

catatan: Evaluasi kuantitatif menunjukkan konsistensi penghematan di atas 25% setiap minggu berkat penyesuaian durasi pompa secara real-time.

Melalui fakta numerik yang tersaji pada Tabel 3, terbukti bahwa integrasi antara teknologi IoT dan machine learning mampu menekan akumulasi penggunaan air hingga 28,2% jika dibandingkan dengan mekanisme otomatisasi konvensional. Efisiensi alokasi sumber daya ini terjadi sebagai dampak langsung dari kapabilitas arsitektur edge dalam mengalkulasi durasi aktif pompa secara optimal melalui proyeksi kondisi cuaca lokal, alih-alih sekedar merespons

fluktuasi data sensor secara instan. Atas dasar capaian tersebut, implementasi sistem ini menunjukkan tingkat kelayakan operasional yang sangat tinggi untuk diaplikasikan pada wilayah pertanian yang menghadapi kendala krisis air ekstrem.

V. PEMBAHASAN

Bukti eksperimental yang dihimpun dari fase pengujian selama 30 hari ini membuktikan bahwa penggabungan antara algoritma edge machine learning dan sistem telemetri IoT pertanian menawarkan solusi yang adaptif serta hemat sumber daya, jika dikomparasikan dengan arsitektur berbasis respons konvensional. Bagian ini tidak sekadar memaparkan kumpulan data secara parsial, melainkan mengorelasikan temuan tersebut secara kritis ke dalam cakupan ilmiah yang lebih luas, membedah potensi faktor pengganggu (threats to validity) yang teridentifikasi, serta merumuskan peta jalan aplikatif untuk pengembangan di masa depan.

A. Kontekstualisasi Optimasi dan Efisiensi Algoritma

Penurunan akumulasi konsumsi air volumetrik sebesar 28,2% yang teridentifikasi pada Lahan A memperkuat tesis utama bahwa sistem otomatisasi statis berbasis ambang batas pada dasarnya tidak efisien jika diterapkan dalam manajemen pertanian modern. Arsitektur otomatisasi konvensional bekerja dengan mengandalkan siklus umpan balik linier yang kaku, suatu kondisi yang memisahkan mekanisme pengairan secara total dari dinamika kebutuhan atmosferik secara real-time.

Apabila dikomparasikan dengan studi-studi terdahulu, efisiensi yang dihasilkan oleh arsitektur edge berbobot ringan dalam penelitian ini sejalan dengan skema penundaan irigasi berbasis data meteorologi makro yang dikembangkan oleh Smith dkk. (2024), di mana model berbasis cloud milik mereka mencatat rata-rata penghematan air sebesar 24,1%. Kendati demikian, melalui penanaman kalkulasi prediktif evapotranspirasi (ET_c) secara native pada mikrokontroler edge ESP32 yang memiliki latensi rendah, sistem yang dikembangkan dalam riset ini berhasil mengeliminasi ketergantungan penuh terhadap konektivitas awan (cloud dependency) suatu kendala utama yang sebelumnya membatasi fleksibilitas operasional pada model terdahulu tersebut.

Di samping itu, kestabilan regulasi kadar air tanah yang telah divalidasi pada Bagian IV-B mampu mengatasi problem instabilitas zona akar krusial sebagaimana yang dilaporkan oleh Al-Mutairi (2025). Walaupun pendekatan berbasis logika fuzzy menyajikan pemodelan keputusan dinamis yang sangat adaptif terhadap kondisi iklim mikro, metodologi tersebut menuntut proses penyesuaian fungsi keanggotaan (membership function) secara manual dan intensif guna mengantisipasi terjadinya lonjakan nilai melampaui batas (overshoot). Sebaliknya, penyematan interpretasi pola kontinu di dalam arsitektur edge yang kami kembangkan terbukti mampu mengotomatiskan tahapan kalibrasi rumit tersebut secara efektif.

Lewat kalkulasi proyeksi tren iklim mikro, arsitektur yang dikembangkan ini berhasil menjawab kesenjangan teknis yang sebelumnya diidentifikasi oleh Zhao dkk. (2026). Penelitian ini membuktikan bahwa implementasi model machine learning berbobot ringan mampu menghasilkan tingkat presisi estimasi yang tinggi hingga mencapai 94,5%, sekaligus tetap beroperasi secara optimal di dalam lingkungan perangkat keras edge yang memiliki keterbatasan sumber daya.

B. Keterbatasan Penelitian dan Potensi Faktor Pengganggu

Kendati tingkat efisiensi performa yang tinggi telah dibuktikan secara kuantitatif sepanjang fase pengujian, terdapat sejumlah batasan teknis serta kendala operasional yang perlu dipaparkan guna menjamin objektivitas ilmiah dari hasil riset ini:

a. Degradasi Sensor dan Penyimpangan Termal (Thermal Drift): Probe kelembapan tanah kapasitif sangat rentan terhadap efek pemadatan fisik material tanah (substrate settlement) serta akumulasi deposit mineral selama masa penempatan jangka panjang. Perubahan struktural pada media tanam ini berpotensi memicu penyimpangan pembacaan analog (analog drift), sehingga tingkat akurasi operasional dalam jangka panjang akan sangat bergantung pada prosedur kalibrasi berkala.

b. Homogenitas Lingkungan: Fase pengamatan eksperimental ini diselenggarakan pada area terstruktur yang memiliki karakteristik profil vegetasi tunggal serta komposisi media tanam yang seragam. Konsekuensinya, nilai konstanta penskalaan hasil optimasi (α dan β) yang diperoleh sepanjang tahapan training memiliki dependensi spasial yang tinggi (bersifat lokal). Oleh sebab itu, diperlukan proses kalkulasi ulang ataupun implementasi skema adaptive transfer learning apabila sistem ini hendak diaplikasikan pada lahan dengan diversitas jenis tanaman maupun variasi struktur tanah yang heterogen.

c. Keterbatasan Perangkat Keras pada Kondisi Beban Puncak (Peak Load): Kendati skema eksekusi lokal yang dipaparkan secara rinci pada Bagian III-D mampu menekan intensitas tugas latar belakang (background tasks)

sepanjang tahapan prediksi, munculnya anomali lingkungan ekstrem yang menuntut pembaruan model secara cepat dan simultan berisiko menimbulkan kelebihan beban (overhead) pada memori volatil node edge dalam jangka waktu operasional yang panjang.

C. Arah Pengembangan dan Rekomendasi Penelitian Masa Depan

Guna memperluas cakupan kontribusi ilmiah dari penelitian ini, studi lanjutan dapat diarahkan pada beberapa fokus pengembangan strategis untuk mengakselerasi implementasi komputasi edge pada sektor pertanian cerdas (smart agriculture):

a. Adaptive Transfer Learning (Pembelajaran Transfer Adaptif): Eksplorasi lanjutan perlu difokuskan pada pengembangan modul algoritma berkemampuan self-calibration (kalibrasi mandiri), sehingga sistem dapat menyesuaikan diri secara otomatis terhadap karakteristik jenis tanah serta fase perkembangan vegetasi yang baru. Melalui pendekatan ini, proses penyesuaian parameter dapat berjalan tanpa harus melakukan siklus training ulang model dasar (base model) secara manual dan menyeluruh.

b. Topologi Jaringan Multi-Node: Perluasan skala sistem dari arsitektur tunggal berbasis edge gateway menuju implementasi jaringan mesh nirkabel yang terdistribusi dan terdesentralisasi akan membuka peluang bagi terlaksananya regulasi iklim mikro secara lokal. Skema ini sangat krusial untuk mengakomodasi kebutuhan sektor pertanian skala makro yang memiliki karakteristik topografi heterogen atau bervariasi.

c. Integrasi Perangkat Keras Edge yang Mendalam: Eksplorasi pemanfaatan Neural Processing Unit (NPU) khusus yang tertanam pada arsitektur mikrokontroler generasi mutakhir akan membuka jalan bagi implementasi deep learning network secara native dengan tingkat kompleksitas yang lebih tinggi. Contoh konkretnya adalah penerapan struktur Long Short-Term Memory (LSTM) ringkas, yang didesain secara khusus untuk memperkuat akurasi estimasi di tengah kondisi anomali cuaca yang memiliki fluktuasi sangat tinggi.

VI. KESIMPULAN

Penelitian ini telah berhasil merancang, mengimplementasikan, serta menguji keandalan arsitektur irigasi otomatis yang adaptif dan berlatensi rendah melalui integrasi sistem edge computing Internet of Things (IoT) dengan pemodelan machine learning lokal. Melalui data empiris yang diperoleh dari fase evaluasi lapangan secara kontinu selama 30 hari, riset ini secara langsung memberikan solusi atas problematika utama terkait efisiensi alokasi sumber daya serta kemandirian operasional sistem (system autonomy) pada sektor pertanian cerdas. Implementasi algoritma inferensi machine learning berbobot ringan yang dioperasikan secara native pada mikrokontroler ESP32 terbukti mampu menghasilkan tingkat akurasi prediksi kumulatif mencapai 94,5% dalam mengestimasi nilai evapotranspirasi tanaman (ET_c) secara real-time. Keberhasilan ini sekaligus membentuk siklus kendali proaktif yang efektif menjaga stabilitas iklim mikro tanah tanpa memiliki ketergantungan konstan pada konektivitas jaringan cloud.

Sumbangsah ilmiah utama dari penelitian ini bagi perkembangan bidang pertanian presisi global bersandar pada pembuktian kuantitatif atas metrik efisiensi alokasi sumber daya. Arsitektur yang dikembangkan terbukti mampu menekan akumulasi konsumsi air secara sistematis sebesar 28,2% jika dikomparasikan dengan mekanisme pengairan otomatis konvensional yang berbasis nilai ambang batas kaku. Di samping itu, sistem ini sukses mengeliminasi fluktuasi tajam kadar air tanah berwujud pola "gergaji" (sawtooth pattern) yang kerap mengganggu kestabilan sistem otomatisasi reaktif; regulasi dilakukan dengan mempertahankan kelembapan tanah volumetrik secara konstan pada rentang agronomis ideal, yaitu antara 60% sampai 80% dari kapasitas lapangan. Nilai signifikansi praktis ini memberikan kontribusi langsung terhadap manajemen konservasi sumber daya air yang berkelanjutan serta optimasi kondisi iklim mikro, terutama bagi kawasan agraris yang dihadapkan pada krisis kelangkaan air bersih yang kritis.

Kendati menunjukkan efektivitas yang signifikan dalam koridor parameter yang diuji, ruang lingkup operasional dari arsitektur ini masih terikat oleh nilai konstanta training yang bersifat lokal serta risiko penurunan performa sensor kapasitas akibat paparan media tanam dalam jangka panjang. Oleh sebab itu, eksplanasi riset selanjutnya perlu dititikberatkan pada penguatan fungsionalitas adaptif sistem. Langkah tersebut dapat ditempuh melalui perancangan modul transfer learning algoritmik berkemampuan self-calibration, implementasi topologi jaringan mesh nirkabel multi-node yang terdesentralisasi, serta pemanfaatan unit pemrosesan neural edge khusus demi mengakomodasi komputasi model estimasi deep learning yang mencakup diversitas jenis tanaman.

Kontribusi Penulis: [Imam]: Konseptualisasi, Metodologi, Penulisan – Draf Asli, Penulisan – Tinjauan & Penyuntingan, Supervisi. [Moh Gilank Alamsyah]: Perangkat Lunak, Investasi, Kurasi Data, Penulisan, Draf Asli.

Semua penulis telah membaca dan menyetujui versi naskah yang telah diterbitkan.

Pendanaan: -x

Ucapan Terima Kasih: -

Konflik Kepentingan: Para penulis menyatakan tidak memiliki konflik kepentingan.

Ketersediaan Data: -

Persetujuan Berdasarkan Informasi ORCID: Tidak tersedia.

Penulis Pertama: https: -

Penulis Kedua: https: -

Penulis Ketiga: -.

REFERENCES

- [1] N. Jaiswal, T. V. Kumar, and C. Shukla, "Smart drip irrigation systems using IoT: a review of architectures, machine learning models, and emerging trends," *Discover Agriculture*, vol. 3, no. 1, p. 253, Nov. 2025, doi: 10.1007/s44279-025-00430-1.
- [2] M. Mohiuddin, Md. S. Islam, and S. Shanjida, "Internet of Things (IoT)-Based Smart Agriculture Irrigation and Monitoring System Using Ubidots Server," in *ECSA-11*, Basel Switzerland: MDPI, Nov. 2024, p. 99. doi: 10.3390/ecsa-11-20528.
- [3] C.-C. Chiu, C.-L. Li, P.-H. Chen, Y.-C. Li, and E.-H. Lim, "Electromagnetic Imaging in Half-Space Using U-Net with the Iterative Modified Contrast Scheme," *Sensors*, vol. 25, no. 4, p. 1120, 2025, doi: 10.3390/s25041120.
- [4] E. Barilli, P. Luna, F. Flores, and D. Rubiales, "Agronomic Performance of Faba Bean in Mediterranean Environments," *Agronomy*, vol. 15, no. 2, p. 412, 2025, doi: 10.3390/agronomy15020412.
- [5] I. Roca, Ó. Pastor, C. Cetina, and L. Arcega, "Co-evolving scenarios and simulated players to locate bugs that arise from the interaction of software models of video games," *Inf. Softw. Technol.*, vol. 169, p. 107412, 2024, doi: 10.1016/j.infsof.2024.107412.
- [6] L. A. C. Ahakonye, A. Zainudin, M. J. A. Shanto, J.-M. Lee, D.-S. Kim, and T. Jun, "A multi-MLP prediction for inventory management in manufacturing execution system," *Internet of Things*, vol. 26, p. 101156, 2024, doi: 10.1016/j.iot.2024.101156.
- [7] J. A. Clifton, E. F. S. Guy, J. L. Knopp, and J. G. Chase, "Obstructive respiratory disease simulation device," *HardwareX*, vol. 17, p. e00512, 2024, doi: 10.1016/j.ohx.2024.e00512.
- [8] Y. Ke, R. Bian, and R. Chandra, "A unified machine learning framework for basketball team roster construction: NBA and WNBA," *Appl. Soft Comput.*, vol. 153, p. 111298, 2024, doi: 10.1016/j.asoc.2024.111298.
- [9] R. Togneri, R. Prati, H. Nagano, and C. Kamienski, "Data-driven water need estimation for IoT-based smart irrigation: A survey," *Expert Syst. Appl.*, vol. 225, p. 120194, 2023, doi: 10.1016/j.eswa.2023.120194.
- [10] D. Wu, Y. Ren, H. Sørensen, H. Qian, and J. Mou, "Gas-liquid flow patterns visualization in a self-priming centrifugal pump," *Flow Measurement and Instrumentation*, vol. 92, p. 102389, 2023, doi: 10.1016/j.flowmeasinst.2023.102389.
- [11] S. P. de Bruin, J. van Vliet, I. Lehmann, and P. Verburg, "Perceptions of equity in conservation scenarios: Half Earth and Sharing the Planet," *Environ. Sci. Policy*, vol. 144, pp. 124–136, 2023, doi: 10.1016/j.envsci.2023.03.015.
- [12] S. Lin, Z. Yuan, J. Tang, J. Lu, Q. Cao, and Y. Zhai, "Interaxial time-domain interference in single-beam SERF magnetometer," *Measurement*, vol. 215, p. 112890, 2023, doi: 10.1016/j.measurement.2023.112890.
- [13] X. Li, X. Luo, A. Wang, W. Chen, and Q. Huang, "Control factors of soil diazotrophic community assembly and nitrogen fixation rate across eastern China," *Geoderma*, vol. 432, p. 116410, 2023, doi: 10.1016/j.geoderma.2023.116410.
- [14] B. Nsoh *et al.*, "Internet of Things-Based Automated Solutions Utilizing Machine Learning for Smart and Real-Time Irrigation Management: A Review," *Sensors*, vol. 24, no. 23, p. 7480, 2024, doi: 10.3390/s24237480.

- [15] M. Del-Coco, M. Leo, and P. Carcagni, "Machine Learning for Smart Irrigation in Agriculture: How Far along Are We?," *Information*, vol. 15, no. 6, p. 306, 2024, doi: 10.3390/info15060306.
- [16] G. Saha, F. Shahrin, F. H. Khan, M. M. Meshkat, and A. K. M. A. M. Azad, "Smart IoT-driven precision agriculture: Land mapping, crop prediction, and irrigation system," *PLoS One*, vol. 20, no. 3, p. e0319268, 2025, doi: 10.1371/journal.pone.0319268.
- [17] R. Benameur, A. Dahane, B. Kechar, and A. E. H. Benyamina, "An Innovative Smart and Sustainable Low-Cost Irrigation System for Anomaly Detection Using Deep Learning," *Sensors*, vol. 24, no. 4, p. 1162, 2024, doi: 10.3390/s24041162.
- [18] C. Fathy and H. M. Ali, "A Secure IoT-Based Irrigation System for Precision Agriculture Using the Expeditious Cipher," *Sensors*, vol. 23, no. 4, p. 2091, 2023, doi: 10.3390/s23042091.
- [19] G. P. Pereira, M. Z. Chaari, and F. Daroge, "IoT-Enabled Smart Drip Irrigation System Using ESP32," *IoT*, vol. 4, no. 3, pp. 221–243, 2023, doi: 10.3390/iot4030012.
- [20] N. C. Gaitan, B. I. Batinas, C. Ursu, and F. N. Crainiciuc, "Integrating Artificial Intelligence into an Automated Irrigation System," *Sensors*, vol. 25, no. 4, p. 1199, 2025, doi: 10.3390/s25041199.
- [21] A. Kaur, D. P. Bhatt, and L. Raja, "Developing a Hybrid Irrigation System for Smart Agriculture Using IoT Sensors and Machine Learning in Sri Ganganagar, Rajasthan," *J. Sens.*, vol. 2024, pp. 1–15, 2024, doi: 10.1155/2024/6676907.
- [22] P. Suresh, R. H. Aswathy, V. D. Krishnappa, and P. M. Rajasree, "Efficient IoT -Machine Learning Based Smart Irrigation Using Support Tree Algae Algorithm," *IETE J. Res.*, vol. 70, no. 8, pp. 6775–6790, 2024, doi: 10.1080/03772063.2024.2319707.
- [23] 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, 2024, doi: 10.2166/hydro.2024.241.
- [24] M. Benzaouia, B. Hajji, A. Mellit, and A. Rabhi, "Fuzzy-IoT smart irrigation system for precision scheduling and monitoring," *Comput. Electron. Agric.*, vol. 215, p. 108407, 2023, doi: 10.1016/j.compag.2023.108407.
- [25] A. Manocha, S. K. Sood, and M. Bhatia, "IoT-digital twin-inspired smart irrigation approach for optimal water utilization," *Sustainable Computing: Informatics and Systems*, vol. 41, p. 100947, 2024, doi: 10.1016/j.suscom.2023.100947.
- [26] A. Bouteska, T. Sharif, F. Bhuiyan, and M. Z. Abedin, "Impacts of the changing climate on agricultural productivity and food security: Evidence from Ethiopia," *J. Clean. Prod.*, vol. 449, p. 141793, 2024, doi: 10.1016/j.jclepro.2024.141793.
- [27] A. Younes, Z. E. A. Ellassad, O. El Meslouhi, D. E. A. Ellassad, and E. Abdel Majid, "The application of machine learning techniques for smart irrigation systems: A systematic literature review," *Smart Agricultural Technology*, vol. 7, p. 100425, Mar. 2024, doi: 10.1016/j.atech.2024.100425.
- [28] J. Yu, Q. Qu, S. Peng, X. Wei, Y. Li, and C. Sun, "Deep learning for intelligent irrigation decision-making: A review," *Agric. Water Manag.*, vol. 320, p. 109836, 2025, doi: 10.1016/j.agwat.2025.109836.
- [29] S.-Z. Hashemi, A. Darzi-Naftchali, F. Karandish, H. Ritzema, and K. Solaimani, "Enhancing agricultural sustainability with water and crop management strategies in modern irrigation and drainage networks," *Agric. Water Manag.*, vol. 305, p. 109110, 2024, doi: 10.1016/j.agwat.2024.109110.
- [30] Y. Zhang *et al.*, "Research and Development of an IoT Smart Irrigation System for Farmland Based on LoRa and Edge Computing," *Agronomy*, vol. 15, no. 2, p. 366, Jan. 2025, doi: 10.3390/agronomy15020366.
- [31] A. Ali, T. Hussain, and A. Zahid, "Smart Irrigation Technologies and Prospects for Enhancing Water Use Efficiency for Sustainable Agriculture," *AgriEngineering*, vol. 7, no. 4, p. 106, Apr. 2025, doi: 10.3390/agriengineering7040106.
- [32] M. Nawaz and M. I. K. Babar, "IoT and AI for smart agriculture in resource-constrained environments: challenges, opportunities and solutions," *Discover Internet of Things*, vol. 5, no. 1, p. 24, 2025, doi: 10.1007/s43926-025-00119-3.
- [33] R. Sahu and P. Tripathi, "An intelligent framework for monitoring and irrigation prediction for precision agriculture," *Iran Journal of Computer Science*, vol. 8, no. 4, pp. 1389–1423, 2025, doi: 10.1007/s42044-025-00269-1.
- [34] A. Abdulhamid, M. M. Rahman, S. Kabir, and I. Ghafir, "Enhancing Safety in IoT Systems: A Model-Based Assessment of a Smart Irrigation System Using Fault Tree Analysis," *Electronics (Basel)*, vol. 13, no. 6, p. 1156, Mar. 2024, doi: 10.3390/electronics13061156.
- [35] E. Artetxe, O. Barambones, I. Martín Toral, J. Uralde, I. Calvo, and A. del Rio, "Smart IoT Irrigation System Based on Fuzzy Logic, LoRa, and Cloud Integration," *Electronics (Basel)*, vol. 13, no. 10, p. 1949, May 2024, doi: 10.3390/electronics13101949.

- [36] Z. E. Mohamed, M. K. Afify, M. M. Badr, and O. A. Omar, "IoT-driven smart irrigation system to improve water use efficiency," *Sci. Rep.*, vol. 16, no. 1, p. 2609, 2026, doi: 10.1038/s41598-025-33826-6.
- [37] Z. Ye, S. Yin, Y. Cao, and Y. Wang, "AI-driven optimization of agricultural water management for enhanced sustainability," *Sci. Rep.*, vol. 14, no. 1, p. 25721, 2024, doi: 10.1038/s41598-024-76915-8.
- [38] T. Miller, G. Mikiciuk, I. Durlik, M. Mikiciuk, A. Łobodzińska, and M. Śnieg, "The IoT and AI in Agriculture: The Time Is Now—A Systematic Review of Smart Sensing Technologies," *Sensors*, vol. 25, no. 12, p. 3583, 2025, doi: 10.3390/s25123583.
- [39] Md. M. H. Sajib and A. S. Md. Sayem, "Innovations in Sensor-Based Systems and Sustainable Energy Solutions for Smart Agriculture: A Review," *Encyclopedia*, vol. 5, no. 2, p. 67, 2025, doi: 10.3390/encyclopedia5020067.
- [40] F. Puig, M. Garcia-Vila, M. A. Soriano, and J. A. Rodríguez-Díaz, "AquaCrop-IoT: A smart irrigation platform integrating real-time images and weather forecasting," *Comput. Electron. Agric.*, vol. 235, p. 110372, Aug. 2025, doi: 10.1016/j.compag.2025.110372.
- [41] J. Yu, Q. Qu, S. Peng, X. Wei, Y. Li, and C. Sun, "Deep learning for intelligent irrigation decision-making: A review," *Agric. Water Manag.*, vol. 320, p. 109836, Nov. 2025, doi: 10.1016/j.agwat.2025.109836.
- [42] S. K. Kasereka *et al.*, "From IoT to AIoT: Evolving Agricultural Systems Through Intelligent Connectivity in Low-Income Countries," *Future Internet*, vol. 18, no. 2, p. 82, 2026, doi: 10.3390/fi18020082.
- [43] S. Kumari, N. Ali, M. Dagati, and Y. Dong, "IoT-Enabled Soil Moisture and Conductivity Monitoring Under Controlled and Field Fertigation Systems," *AgriEngineering*, vol. 7, no. 7, p. 207, 2025, doi: 10.3390/agriengineering7070207.
- [44] H. Sharifnasab, A. Mahrok, H. Dehghanisani, E. Łazuka, G. Łagód, and H. Karami, "Evaluating the Use of Intelligent Irrigation Systems Based on the IoT in Grain Corn Irrigation," *Water (Basel)*, vol. 15, no. 7, p. 1394, Apr. 2023, doi: 10.3390/w15071394.
- [45] A. Morchid, I. G. Muhammad Alblushi, H. M. Khalid, R. El Alami, S. R. Sitaramanan, and S. M. Muyeen, "High-technology agriculture system to enhance food security: A concept of smart irrigation system using Internet of Things and cloud computing," *Journal of the Saudi Society of Agricultural Sciences*, Feb. 2024, doi: 10.1016/j.jssas.2024.02.001.
- [46] M. B. Islam, A. Guerrieri, R. Gravina, D. T. Delaney, and G. Fortino, "From Traditional Machine Learning to Fine-Tuning Large Language Models: A Review for Sensors-Based Soil Moisture Forecasting," *Sensors*, vol. 25, no. 22, p. 6903, 2025, doi: 10.3390/s25226903.
- [47] A. Subeesh, N. Chauhan, and N. L. Kushwaha, "Integrating IoT With Machine Learning and Deep Learning Models for Precision Soil-Less Agriculture: A Review," *Artificial Intelligence for Engineering*, vol. 1, no. 2, pp. 137–164, 2025, doi: 10.1049/aie2.70005.
- [48] O. P.-C. Ugwu *et al.*, "Implementing artificial intelligence and machine learning algorithms for optimized crop management: a systematic review on data-driven approach to enhancing resource use and agricultural sustainability," *Cogent Food Agric.*, vol. 11, no. 1, Dec. 2025, doi: 10.1080/23311932.2025.2569982.
- [49] S. Violino *et al.*, "A data-driven bibliometric review on precision irrigation," *Smart Agricultural Technology*, vol. 5, p. 100320, Oct. 2023, doi: 10.1016/j.atech.2023.100320.
- [50] S. Mansoor, S. Iqbal, S. M. Popescu, S. L. Kim, Y. S. Chung, and J.-H. Baek, "Integration of smart sensors and IOT in precision agriculture: trends, challenges and future perspectives," *Front. Plant Sci.*, vol. 16, May 2025, doi: 10.3389/fpls.2025.1587869.
- [51] A. Morchid, Z. Said, A. Y. Abdelaziz, P. Siano, and H. Qjidaa, "Fuzzy logic-based IoT system for optimizing irrigation with cloud computing: Enhancing water sustainability in smart agriculture," *Smart Agricultural Technology*, vol. 11, p. 100979, Aug. 2025, doi: 10.1016/j.atech.2025.100979.
- [52] A. A. Lozano-Povis, "Agricultura y cambio climático: principales hallazgos y propuestas para la toma de decisiones en dos regiones naturales del Perú," *South Sustainability*, vol. 4, no. 1, p. e068, 2023, doi: 10.21142/SS-0401-2023-e068.
- [53] U. Roy B.P, K. N. A. Sattar, and A. A. Elngar, "A Smart Irrigation System Using the IoT and Advanced Machine Learning Model," *Journal of Smart Internet of Things*, vol. 2024, no. 2, pp. 13–25, Dec. 2024, doi: 10.2478/jsiot-2024-0009.
- [54] V. S. Reddy, S. Harivardhini, and G. Sreelakshmi, "IoT and Cloud Based Sustainable Smart Irrigation System," *E3S Web of Conferences*, vol. 472, p. 01026, Jan. 2024, doi: 10.1051/e3sconf/202447201026.