

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Internet of Things (IoT) dan Smart Agriculture

Internet of Things (IoT) didefinisikan sebagai paradigma di mana objek fisik dilengkapi dengan sensor, kemampuan pemrosesan, dan teknologi komunikasi untuk bertukar data melalui internet. (Domínguez-Bolaño et al., 2022) menjelaskan bahwa arsitektur IoT umumnya terdiri dari tiga lapisan utama, yaitu:

- a. *Perception Layer* yang berfungsi sebagai pengumpul data melalui sensor dan aktuator.
- b. *Network Layer* yang bertanggung jawab terhadap transmisi data menggunakan protokol komunikasi seperti Wi-Fi dan MQTT.
- c. *Application Layer* yang menyediakan layanan analisis data dan antarmuka pengguna.

Dalam konteks pertanian, implementasi IoT berkembang menjadi konsep *Smart Agriculture*, yang memungkinkan pemantauan kondisi lingkungan secara presisi dan *real-time* guna meningkatkan efisiensi penggunaan sumber daya, khususnya air irigasi (Domínguez-Bolaño et al., 2022). Dalam penelitian ini, *perception layer* direpresentasikan oleh sensor lingkungan, *network layer* oleh konektivitas Wi-Fi, dan *application layer* oleh sistem *Digital Twin* untuk analisis dan pengambilan keputusan irigasi.

2.1.2 Konsep Adaptive Digital Twin

Digital Twin (DT) dalam pertanian didefinisikan sebagai representasi *virtual* dari entitas fisik seperti tanaman atau sistem irigasi yang diperbarui secara *real-time* melalui aliran data dua arah (*bi-directional data flow*) antara sistem fisik dan virtual (Zhang et al., 2025). Berbeda dengan model simulasi statis, *Digital Twin* memungkinkan integrasi pemantauan, simulasi, dan pengambilan keputusan dalam satu kerangka kerja terpadu.

Penelitian ini mengadopsi konsep *Adaptive Digital Twin*. Menurut (Ogunsakin, Mehandjiev and Marin, 2023), suatu *Digital Twin* dikategorikan adaptif apabila memiliki kemampuan RSO²A (*Real-time Simulation, Online Optimization, and Adaptivity*). Artinya, model virtual tidak hanya memvisualisasikan kondisi fisik, tetapi juga mampu menyesuaikan parameter internalnya secara otomatis berdasarkan perubahan lingkungan nyata yang diterima dari sensor. Sebagai contoh, perubahan intensitas cahaya yang signifikan dapat memicu pembaruan parameter model prediksi untuk menghasilkan rekomendasi irigasi yang lebih akurat (Ogunsakin, Mehandjiev and Marin, 2023).

2.1.3 Perangkat Keras (Hardware)

a. Mikrokontroler ESP32

ESP32 merupakan *System on Chip* (SoC) berbiaya rendah yang mengintegrasikan prosesor Xtensa® 32-bit LX6 dengan modul *Wi-Fi* dan *Bluetooth* ganda. (Hercog et al., 2023) menekankan bahwa ESP32 memiliki efisiensi daya yang baik serta kemampuan pemrosesan yang memadai untuk menjalankan aplikasi IoT. Dalam arsitektur terdistribusi, ESP32 berperan

sebagai *intelligent edge node* yang menangani akuisisi data sensor secara simultan dan eksekusi instruksi aktuator secara *real-time*. Karakteristik ini menjadikan ESP32 ideal untuk menjembatani sistem fisik dengan representasi *virtual* dalam kerangka kerja *Digital Twin* skala mikro.

b. Sensor Suhu dan Kelembapan Udara (DHT22)

DHT22 merupakan sensor digital presisi tinggi yang dirancang untuk mengukur suhu dan kelembapan udara secara simultan. Sensor ini beroperasi dengan memanfaatkan termistor tipe NTC (*Negative Temperature Coefficient*) untuk pengukuran suhu dan elemen kapasitif polimer untuk mendeteksi perubahan kelembapan relatif udara. Data analog yang diakuisisi oleh kedua elemen tersebut kemudian dikonversi menjadi sinyal digital melalui mikrokontroler internal 8-bit yang terintegrasi di dalam modul sensor, sebelum ditransmisikan ke mikrokontroler utama (Wardani et al., 2023). Penggunaan DHT22 sangat relevan dalam arsitektur sistem pertanian pintar karena kemampuannya dalam menyediakan data iklim mikro yang stabil (Hilal et al., 2022). Parameter suhu dan kelembapan udara yang diukur oleh instrumen ini merupakan variabel meteorologis esensial yang secara langsung memengaruhi dinamika laju evapotranspirasi pada lingkungan fisik tanaman.

c. Sensor Intensitas Cahaya (BH1750)

BH1750 merupakan sensor cahaya digital yang mengukur tingkat iluminansi dalam satuan Lux menggunakan antarmuka I2C (*Inter-Integrated Circuit*). Protokol I2C merupakan standar komunikasi serial dua kabel yang terdiri dari jalur data (SDA) dan jalur detak (SCL), yang memungkinkan

transmisi data digital antara sensor dan mikrokontroler secara sinkron dengan meminimalkan penggunaan pin serta risiko gangguan sinyal. Sensor ini memiliki respons spektral yang mendekati sensitivitas mata manusia. (Jannah and Aulia, 2025) menunjukkan bahwa penerapan metode regresi linear pada pembacaan sensor BH1750 mampu meningkatkan akurasi pengukuran intensitas cahaya matahari, yang berperan penting sebagai proksi sederhana radiasi matahari dalam perhitungan laju evapotranspirasi tanaman.

d. Sensor Kelembapan Tanah Kapasitif

Penelitian ini menggunakan sensor kelembapan tanah tipe kapasitif yang bekerja berdasarkan prinsip perubahan permitivitas dielektrik media tanam. Permitivitas dielektrik merupakan kemampuan tanah dalam menyimpan energi listrik, di mana penambahan volume air di dalam tanah akan secara langsung mengubah nilai kapasitansi yang terbaca oleh instrumen sensor. Pemilihan tipe kapasitif ini didasarkan pada keunggulannya dibandingkan tipe resistif. Berdasarkan studi komparasi terbaru oleh (Agustirandi et al., 2024), sensor resistif memiliki kelemahan signifikan berupa kerentanan terhadap korosi elektroda dan stabilitas data yang rendah dalam pengukuran jangka panjang. Sebaliknya, sensor kapasitif terbukti memiliki tingkat akurasi dan stabilitas yang lebih tinggi (R^2 mencapai 0,980) karena elektrodanya terisolasi dan mengukur perubahan konstanta dielektrik tanah tanpa kontak listrik langsung (*contact-less*).

Selain unggul dalam durabilitas, sensor kapasitif berbiaya rendah (*low-cost*) terbukti mampu menghasilkan pengukuran yang presisi jika dikalibrasi dengan

benar. Riset yang dilakukan (Abdelmoneim et al., 2025) menunjukkan bahwa sensor kapasitif murah (tipe SEN0193) mampu mencapai akurasi prediksi kadar air yang tinggi dengan *Root Mean Square Error* (RMSE) di bawah 5% setelah melalui kalibrasi spesifik pada tanah lempung berdebu. Temuan ini diperkuat oleh (Raheja et al., 2025), yang membuktikan bahwa performa sensor kapasitif *low-cost* yang telah dikalibrasi lapangan memiliki korelasi sangat kuat ($r > 0,98$) dengan sensor komersial berstandar industri (SM150T). Atas dasar stabilitas, ketahanan korosi, dan potensi akurasi tersebut, sensor kapasitif dipilih sebagai instrumen pengukuran utama dalam penelitian ini.

e. Unit Aktuator (Modul Relay dan Pompa Air Mini)

Dalam ekosistem *Internet of Things* (IoT), aktuator berfungsi sebagai pengeksekusi perintah fisik berdasarkan keputusan komputasional atau logika kontrol yang ditetapkan. Modul relay bertindak sebagai sakelar elektromekanis yang memungkinkan mikrokontroler berdaya rendah (*low-level logic*) seperti ESP32 untuk mengendalikan rangkaian bertegangan atau berarus lebih tinggi, dalam hal ini adalah pompa air mini. Ketika sinyal aktuasi (*trigger*) diterima dari *edge node*, kumparan elektromagnetik di dalam relay akan mengubah status kontak dari kondisi *Normally Open* (NO) menjadi tertutup (*Closed*), sehingga mengalirkan daya listrik menuju pompa. Integrasi antara relay dan pompa air ini merupakan infrastruktur kritis yang memungkinkan transisi dari sistem pemantauan pasif menjadi sistem irigasi cerdas yang mampu melakukan intervensi fisik secara otonom terhadap media tanam (García et al., 2020; Morchid et al., 2025).

2.1.4 Teknik Pengolahan Sinyal (Signal Processing)

Data yang dihasilkan oleh sensor lingkungan, khususnya sensor kelembapan tanah kapasitif, seringkali mengandung derau (*noise*) akibat fluktuasi tegangan mikro atau interferensi elektromagnetik. Oleh karena itu, diperlukan teknik pra-pemrosesan sinyal untuk meningkatkan kualitas data sebelum digunakan dalam model *Machine Learning*.

a. Binning dan Median Filtering

Teknik *Binning* merupakan metode diskritisasi data kontinu ke dalam sejumlah interval (*bins*) kecil untuk mengurangi dampak variabilitas data minor (Han, Pei and Tong, 2023). Dalam setiap interval, penggunaan nilai tengah (Median) lebih disukai dibandingkan rata-rata (*Mean*) karena sifatnya yang *robust* terhadap pencilan (*outlier*) ekstrem (Hou et al., 2021).

b. Filter Savitzky-Golay

Filter Savitzky-Golay adalah metode penghalusan data (*smoothing*) yang bekerja dengan cara menyesuaikan polinomial derajat rendah pada sub-himpunan data di dalam jendela geser (*sliding window*) menggunakan metode kuadrat terkecil. Keunggulan utama filter ini dibandingkan rata-rata bergerak (*moving average*) biasa adalah kemampuannya dalam mempertahankan bentuk asli sinyal, termasuk puncak dan lembah data, tanpa menyebabkan distorsi sinyal yang signifikan (Bandaru et al., 2024).

2.1.5 Machine Learning dan Deep Learning

Machine Learning (ML) merupakan cabang kecerdasan buatan yang memungkinkan sistem belajar dari data tanpa pemrograman eksplisit. (Taye, 2023)

membedakan ML klasik dan *Deep Learning* (DL). Algoritma ML klasik, seperti *Random Forest*, umumnya memerlukan ekstraksi fitur manual, sedangkan DL menggunakan jaringan saraf berlapis (*multi-layer neural networks*) untuk mengekstraksi representasi fitur tingkat tinggi secara otomatis dari data mentah. Perbedaan fundamental ini menjadi dasar pemilihan *Random Forest* dan LSTM sebagai objek komparasi dalam penelitian ini.

2.1.6 Algoritma Random Forest (RF)

Random Forest adalah algoritma *ensemble learning* yang diperkenalkan oleh (Breiman, 2001). Algoritma ini membangun sejumlah pohon keputusan yang dilatih menggunakan teknik *bootstrap aggregating* (bagging). Untuk kasus regresi, prediksi *Random Forest* dirumuskan sebagai rata-rata keluaran seluruh pohon keputusan:

$$\hat{y} = \frac{1}{N} \sum_{i=1}^N T_i(x) \quad (2.1)$$

di mana $T_i(x)$ merupakan prediksi pohon ke- i dan N adalah jumlah pohon. Mekanisme pengacakan pada pemilihan data dan fitur membuat *Random Forest* tahan terhadap *overfitting* dan *robust* terhadap *noise*, sehingga sesuai digunakan sebagai model *baseline* (Breiman, 2001).

2.1.7 Algoritma Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah varian *Recurrent Neural Network* (RNN) yang diperkenalkan oleh (Hochreiter and Schmidhuber, 1997) untuk mengatasi permasalahan *vanishing gradient*. LSTM mampu mempelajari

ketergantungan jangka panjang pada data runtun waktu melalui struktur sel memori (*cell state*) yang diperbarui secara aditif.

Secara umum, operasi LSTM dirumuskan sebagai:

$$\begin{aligned} f_t &= \sigma(W_f[h_{t-1}, x_t] + b_f) \\ i_t &= \sigma(W_i[h_{t-1}, x_t] + b_i) \\ C_t &= f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \end{aligned} \quad (2.2)$$

Struktur gerbang ini memungkinkan gradien mengalir lebih stabil sepanjang waktu, sehingga LSTM efektif dalam memodelkan dinamika kelembapan tanah dan faktor lingkungan yang berubah secara temporal (Hochreiter and Schmidhuber, 1997).

2.1.8 Metrik Evaluasi Model

Untuk mengevaluasi kinerja model regresi dalam memprediksi kelembapan tanah secara holistik, penelitian ini menggunakan kombinasi tiga metrik utama, yaitu *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan Koefisien Determinasi (R^2). Dua metrik pertama, yaitu RMSE dan MAE, berfungsi untuk mengukur besarnya magnitudo kesalahan prediksi terhadap nilai aktual (Hodson, 2022), Secara matematis, kedua metrik tersebut dirumuskan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.4)$$

Di mana y_i merupakan nilai aktual hasil pengukuran sensor, $\hat{y}_i$ merupakan nilai hasil prediksi model, dan n adalah jumlah data pengamatan. RMSE memberikan penalti lebih besar terhadap kesalahan ekstrem karena melibatkan operasi pengkuadratan, sehingga sensitif terhadap *outlier*. Sementara itu, MAE merepresentasikan rata-rata kesalahan absolut yang lebih mudah diinterpretasikan secara langsung.

Namun, pengukuran besaran *error* saja tidak cukup untuk menilai kualitas model pada data runtun waktu. Oleh karena itu, digunakan Koefisien Determinasi (R^2) untuk mengukur kemampuan model dalam mereplikasi variasi dan pola data observasi (Chicco, Warrens and Jurman, 2021). Rumus R^2 didefinisikan sebagai:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (2.5)$$

Nilai R^2 berkisar antara $-\infty$ hingga 1, di mana nilai yang mendekati 1 menunjukkan kemampuan prediksi yang sangat baik dalam menangkap dinamika data, sedangkan nilai R^2 yang rendah atau bernilai negatif mengindikasikan bahwa performa model lebih buruk daripada sekadar menebak nilai rata-rata data. Kombinasi ketiga metrik ini memastikan evaluasi tidak hanya berfokus pada minimnya error, tetapi juga ketepatan model dalam mengikuti tren fluktuasi kelembapan tanah.

2.2 Penelitian Terkait

Tinjauan terhadap penelitian terdahulu dilakukan untuk memetakan perkembangan riset di bidang irigasi presisi berbasis *Internet of Things* (IoT) dan kecerdasan buatan, serta untuk mengidentifikasi kesenjangan penelitian (*research*

gap) yang masih terbuka. Berdasarkan penelusuran literatur secara sistematis pada rentang tahun 2020-2025, penelitian-penelitian yang relevan dalam bidang ini dapat dikelompokkan ke dalam tiga pendekatan utama. Pendekatan pertama adalah sistem irigasi berbasis IoT konvensional yang dipadukan dengan metode *Machine Learning* klasik. Pendekatan kedua berfokus pada penerapan metode *Deep Learning* untuk pengolahan data runtun waktu (*time-series*). Sementara itu, pendekatan ketiga mengarah pada penerapan konsep *Digital Twin* dalam sistem irigasi presisi.

Pendekatan pertama umumnya memanfaatkan sensor lingkungan dan algoritma regresi atau klasifikasi sederhana untuk mengotomasi irigasi. Pendekatan ini relatif ringan secara komputasi, namun cenderung bersifat reaktif karena keputusan irigasi hanya didasarkan pada kondisi saat ini tanpa kemampuan prediksi jangka panjang. Pendekatan kedua mulai mengadopsi model *Deep Learning*, khususnya *Long Short-Term Memory* (LSTM), yang dirancang untuk menangkap dependensi temporal pada data lingkungan yang fluktuatif. Sementara itu, pendekatan ketiga memperkenalkan konsep *Digital Twin* sebagai representasi virtual dari sistem fisik pertanian yang memungkinkan pemantauan dan simulasi secara lebih komprehensif.

Ringkasan komprehensif dari penelitian-penelitian kunci, termasuk metode yang digunakan, variabel *input*, hasil utama, serta keterbatasan masing-masing studi, disajikan dalam Tabel 2.1. Tabel ini sekaligus digunakan sebagai dasar untuk melakukan analisis kesenjangan penelitian.

Tabel 2.1 Matriks Penelitian Terkait dan Analisis Kesenjangan

No	Penulis (Tahun)	Metode / Algoritma	Variabel Input (Sensor)	Hasil Utama	Keterbatasan (Research Gap)
1	Bautista et al., (2025)	Digital Twin + ML	Soil Moisture, Data Cuaca	Kerangka kerja <i>Digital Twin</i> untuk optimasi air <i>real-time</i> .	Implementasi masih berupa simulasi tingkat tinggi, belum diuji pada perangkat <i>edge</i> (mikrokontroler) berdaya rendah.
2	Kandamali et al., (2025a)	LSTM vs Ensemble	Soil Moisture, Temperature, Humidity	LSTM menghasilkan <i>error</i> (RMSE) terendah dibanding metode ensemble.	Model hanya mengandalkan suhu & kelembapan, tidak mengintegrasikan intensitas cahaya sebagai faktor evaporasi.
3	Parewai & Köppen, (2025)	Digital Twin + Simulasi	Data Visual (Kamera)	Estimasi kelembapan tanah berbasis visual (<i>rendering</i>).	Membutuhkan komputasi berat (GPU) untuk <i>rendering</i> , tidak cocok untuk sistem IoT hemat energi.
4	Chen et al., (2025)	Random Forest (RF)	Curah Hujan, Soil Moisture	Prediksi kadar air tanah lintas musim menggunakan RF.	Akurasi RF menurun pada data jangka panjang karena kurang optimal menangkap pola sekuensial (<i>time-series</i>).
5	Custódio & Prati, (2024)	LSTM vs Random Forest	Temperature, Humidity, Soil Moisture	Membuktikan LSTM unggul signifikan atas RF pada data <i>time-series</i> .	Fokus pada akurasi model saja, belum diimplementasikan dalam mekanisme kontrol irigasi adaptif otomatis.
6	Tace et al., (2022)	IoT + ML (KNN/SVM)	Soil Moisture, Temperature, Humidity	Sistem irigasi cerdas hemat energi berbasis IoT dan ML.	Model ML yang digunakan (KNN/SVM) bersifat klasifikasi sederhana, bukan prediksi <i>time-series</i> kontinu yang dinamis.
7	Domínguez-Bolaño et al., (2022)	Review Sensor IoT	Berbagai Sensor Tanah	Tinjauan tren sensor irigasi dan arsitektur IoT.	Menyoroti tantangan kalibrasi sensor tanah, namun tidak menawarkan solusi algoritma prediksi tingkat lanjut.
8	Kandamali et al., (2025b)	Hybrid LSTM + XGBoost	Soil Moisture (<i>history</i>), Suhu, Kelembapan, Solar Radiation, Curah Hujan	Model Hybrid (LSTM-XGBoost) mencapai akurasi tertinggi (R^2 98,67%) dibanding model tunggal.	Menggunakan arsitektur hybrid yang kompleks dan berat secara komputasi (<i>server-side</i>), serta mengandalkan stasiun cuaca lengkap yang mahal, bukan sensor node mandiri yang efisien biaya.

No	Penulis (Tahun)	Metode / Algoritma	Variabel Input (Sensor)	Hasil Utama	Keterbatasan (Research Gap)
9	Harini et al., (2025)	<i>Rule-based (Thresholding) + IoT</i>	LDR (Cahaya), <i>Soil Moisture</i>	Sistem IoT berhasil mengotomatisasi penyiraman dan pencahayaan berdasarkan ambang batas sensor.	Sistem mengandalkan logika ambang batas statis (thresholding) yang reaktif, sehingga kurang optimal dalam melakukan antisipasi preventif terhadap deplesi air yang cepat.
10	Geng et al., (2024)	<i>Physically-guided LSTM (PHY-LSTM)</i>	Data Meteorologi Global (ERA5-Land), <i>Soil Texture</i>	Membuktikan bahwa menambahkan kendala fisik (seperti neraca air & radiasi) pada LSTM meningkatkan akurasi prediksi secara signifikan.	Studi berbasis data satelit/reanalisis global (skala besar), belum diuji validitasnya menggunakan data sensor IoT lokal yang memiliki <i>noise</i> tinggi.

2.2.1 Analisis Penelitian Terkait

Berdasarkan Matriks Penelitian Terkait pada Tabel 2.1, dapat diamati adanya transisi pendekatan dalam pengembangan sistem irigasi cerdas, dari sistem yang bersifat reaktif menuju sistem prediktif yang lebih presisi. Sejumlah penelitian terkini mulai mengadopsi konsep *Digital Twin* untuk merepresentasikan kondisi fisik lahan secara virtual guna mendukung pengambilan keputusan secara *real-time* (Bautista, Gallegos and Lampayan, 2025; Parewai and Köppen, 2025). Meskipun pendekatan ini menunjukkan potensi optimasi penggunaan air yang tinggi, implementasinya pada umumnya masih bergantung pada simulasi tingkat lanjut yang berjalan pada server dengan kebutuhan komputasi besar. Ketergantungan ini menjadi hambatan teknis bagi penerapan *Digital Twin* pada ekosistem pertanian skala kecil yang mengandalkan perangkat IoT berdaya rendah.

Dari sisi algoritma, studi komparatif pada data lingkungan berbentuk *time-series* menunjukkan bahwa algoritma *Deep Learning*, khususnya *Long Short-Term Memory* (LSTM), cenderung lebih unggul dalam menangkap dinamika temporal jangka panjang dibandingkan metode *ensemble* seperti *Random Forest* (Custódio and Prati, 2024; Kandamali et al., 2025a). Meskipun *Random Forest* dikenal stabil dan relatif tahan terhadap *noise*, beberapa penelitian melaporkan adanya penurunan performa ketika metode ini diaplikasikan pada data dengan ketergantungan temporal yang kompleks (Chen et al., 2025). Namun demikian, penerapan model *Deep Learning* yang akurat sering kali memiliki kompleksitas matriks dan beban komputasi yang melampaui kapasitas memori mikrokontroler *low-cost*. Oleh karena itu, diperlukan strategi arsitektur yang mampu menyeimbangkan akurasi model prediktif dengan ketersediaan sumber daya perangkat keras tanpa mengorbankan sifat adaptif sistem.

Selain tantangan komputasi, aspek pemilihan variabel *input* juga menjadi keterbatasan yang cukup menonjol dalam penelitian terdahulu. Mayoritas model masih berfokus pada parameter dasar seperti suhu dan kelembapan udara, serta kelembapan tanah (Tace et al., 2022; Kandamali et al., 2025a), sementara peran intensitas cahaya atau radiasi matahari belum banyak dimanfaatkan secara eksplisit. Padahal, beberapa studi menunjukkan bahwa integrasi variabel radiasi matahari berkontribusi penting dalam merepresentasikan proses fisik evapotranspirasi secara lebih konsisten, baik melalui pendekatan berbasis fisika maupun model *hybrid* (Geng et al., 2024; Kandamali et al., 2025b). Akan tetapi, solusi yang ada umumnya mengandalkan data dari stasiun cuaca lengkap atau sumber data berskala besar,

sehingga kurang kompatibel untuk sistem sensor mandiri yang dirancang dengan keterbatasan biaya dan energi.

Di sisi lain, pada tingkat implementasi perangkat keras, sensor cahaya sebenarnya telah mulai digunakan dalam beberapa sistem IoT pertanian (Harini, Kaliaperumal and Ganapathy, 2025). Namun, pemanfaatannya masih terbatas pada kontrol reaktif berbasis ambang batas, dan belum dimaksimalkan sebagai variabel prediktor dalam model cerdas untuk mengantisipasi perubahan kondisi tanah. Berdasarkan kondisi tersebut, dapat disimpulkan bahwa masih terdapat kesenjangan penelitian yang mengarah pada kebutuhan akan sistem irigasi cerdas yang mampu mengombinasikan pemodelan prediktif berbasis LSTM, pemanfaatan intensitas cahaya sebagai variabel penting, serta arsitektur efisiensi komputasi yang sesuai untuk perangkat IoT berdaya rendah.

2.3 Kebaruan Penelitian (Novelty)

Berdasarkan analisis kesenjangan penelitian yang telah diuraikan pada Subbab 2.2, penelitian ini mengajukan tiga aspek kebaruan utama yang membedakannya secara konseptual maupun implementatif dari penelitian-penelitian sebelumnya, yaitu sebagai berikut.

2.3.1 Integrasi Variabel Intensitas Cahaya dalam Model Prediksi

Berbeda dengan penelitian (Custódio and Prati, 2024) dan (Kandamali et al., 2025a) yang hanya memanfaatkan variabel suhu dan kelembapan, atau (Geng et al., 2024) yang menggunakan data satelit skala global, penelitian ini mengintegrasikan sensor intensitas cahaya (BH1750) sebagai salah satu variabel *input* utama. Integrasi ini didasarkan pada pertimbangan ilmiah bahwa paparan radiasi matahari

berperan signifikan dalam proses evapotranspirasi dan pengeringan tanah. Dengan memasukkan variabel intensitas cahaya, model prediksi diharapkan mampu merepresentasikan kondisi lingkungan secara lebih realistis dan meningkatkan akurasi prediksi kelembapan tanah.

2.3.2 Implementasi Adaptive Digital Twin Berbasis Arsitektur Cloud-Edge IoT

Penelitian ini mengisi celah yang ditinggalkan oleh studi *Digital Twin* pertanian sebelumnya, seperti yang dilakukan oleh (Bautista, Gallegos and Lampayan, 2025) dan (Zhang et al., 2025), yang mayoritas masih mengandalkan komputasi terpusat yang kaku. Berbeda dengan pendekatan tersebut, penelitian ini membangun sistem *Adaptive Digital Twin* menggunakan arsitektur *Cloud-Edge* IoT. Dalam skema ini, beban kerja didistribusikan secara strategis: mikrokontroler ESP32 difokuskan murni sebagai *edge node* untuk prapemrosesan data sensor dan kendali aktuasi di sisi lapangan, sementara beban matriks prediktif algoritma LSTM yang berat dieksekusi melalui infrastruktur komputasi awan (*Cloud Computing*) untuk menjamin akurasi maksimal. Sifat adaptif diwujudkan melalui sinkronisasi data historis dan prediksi secara *real-time* antara *edge node*, basis data *cloud* (ThingSpeak), dan antarmuka pengguna (Blynk), menjadikannya solusi yang efisien, tangguh terhadap keterbatasan memori mikrokontroler, dan relevan untuk penerapan irigasi presisi secara otonom.

2.3.3 Evaluasi Komparatif Deep Learning dan Ensemble Learning dengan Pertimbangan Resource

Penelitian ini melakukan evaluasi komparatif antara algoritma *Long Short-Term Memory* (LSTM) sebagai representasi *Deep Learning* dan *Random Forest* sebagai representasi *Ensemble Learning* ketika diimplementasikan pada ekosistem IoT. Evaluasi tidak hanya berfokus pada akurasi prediksi, tetapi juga menganalisis implikasi kebutuhan sumber daya komputasi (*resource constraints*) dari masing-masing model. Dengan demikian, penelitian ini memberikan kontribusi empiris terkait *trade-off* antara kompleksitas algoritma prediksi dengan kelayakan fisik perangkat keras mikrokontroler yang bermuara pada pemilihan arsitektur terdistribusi.

Ketiga aspek kebaruan tersebut secara kolektif menempatkan penelitian ini sebagai upaya integratif yang menggabungkan pendekatan prediktif, adaptif, dan implementatif dalam konteks irigasi presisi berbasis IoT.