

BAB III

METODE PENELITIAN

3.1 Skema Adaptive Digital Twin

Skema *Adaptive Digital Twin* dalam penelitian ini dirancang sebagai respons terhadap keterbatasan sistem irigasi konvensional maupun sistem IoT reaktif yang hanya bekerja berdasarkan ambang batas statis. Pada praktiknya, kondisi lingkungan pertanian bersifat dinamis dan memiliki pola perubahan yang dipengaruhi oleh waktu, sehingga diperlukan pendekatan yang mampu membaca kecenderungan perubahan tersebut, bukan sekadar merespons kondisi saat ini.

Arsitektur sistem yang dikembangkan mengintegrasikan lingkungan fisik dengan representasi digital melalui mekanisme umpan balik tertutup (*closed-loop system*). Sistem fisik mencakup tanaman cabai rawit, media tanam, serta kondisi lingkungan budidaya. Seluruh parameter ini dipantau secara kontinu menggunakan sensor pada lapisan IoT (*perception layer*), yang mengukur kelembapan tanah, suhu udara, kelembapan udara, serta intensitas cahaya dalam bentuk data runtun waktu (*time-series*).

Data sensor yang diperoleh diakuisisi oleh mikrokontroler ESP32 yang bertindak murni sebagai *edge node*. Data tersebut kemudian ditransmisikan menuju basis data *cloud* (ThingSpeak) untuk penyimpanan jangka panjang. Pada tahap ini, aliran data historis yang tersimpan di *cloud* digunakan sebagai masukan (*input*) bagi model prediksi algoritma *Machine Learning* yang dieksekusi pada infrastruktur *server* (*Cloud Computing*). Model inilah yang menjadi otak analitis dari *Adaptive*


Digital Twin, yang memproyeksikan kondisi kelembapan tanah pada waktu mendatang berdasarkan pola historis dan variabel lingkungan yang terukur.

Hasil prediksi selanjutnya diteruskan ke modul pengambilan keputusan (*decision engine*), yang menentukan apakah pompa air perlu diaktifkan atau dihentikan. Keputusan ini tidak lagi didasarkan pada nilai ambang sederhana, melainkan mempertimbangkan estimasi kondisi tanah ke depan. Instruksi aktuasi tersebut kemudian dikirim kembali ke ESP32 melalui antarmuka *Application Programming Interface* (API). Dengan pendekatan ini, sistem diharapkan mampu menjaga kelembapan tanah tetap berada dalam rentang optimal sesuai kebutuhan tanaman.

Selain berfungsi sebagai pengendali otomatis, sistem juga menyediakan visualisasi kondisi aktual dan hasil prediksi melalui *dashboard* antarmuka (Blynk). Tampilan ini merepresentasikan kondisi *digital twin* secara *real-time*, sehingga pengguna dapat memantau keterkaitan antara kondisi fisik dan hasil analisis model.

Ketika pompa air diaktifkan, perubahan kadar air tanah yang terjadi akan kembali terdeteksi oleh sensor dan dikirimkan ke sistem. Proses ini membentuk siklus adaptif yang berlangsung secara berulang, memungkinkan sistem menyesuaikan strategi irigasi terhadap dinamika lingkungan yang berubah.


Skema keseluruhan mekanisme *Adaptive Digital Twin* pada sistem irigasi presisi ini ditunjukkan pada Gambar 3.1.



Gambar 3.1 Skema Sistem Irigasi Presisi Adaptif

3.2 Alur Penelitian

Pelaksanaan penelitian ini disusun dalam tahapan yang terstruktur agar setiap proses pengembangan sistem dan pemodelan dapat dilakukan secara sistematis. Alur penelitian mengacu pada rancangan *Adaptive Digital Twin* yang telah dijelaskan pada Subbab 3.1, dan dirangkum dalam bentuk diagram alir sebagaimana ditunjukkan pada Gambar 3.2.



Gambar 3.2 Diagram Alir Penelitian

Berdasarkan diagram tersebut, penelitian dibagi ke dalam empat fase utama yang saling berkaitan.

Fase pertama merupakan tahap konseptual, yang meliputi studi literatur dan identifikasi permasalahan. Pada tahap ini dilakukan penelusuran referensi terkait sistem irigasi presisi, konsep *Digital Twin*, serta pendekatan *machine learning* untuk prediksi kelembapan tanah. Proses ini bertujuan untuk memetakan posisi penelitian serta mengidentifikasi kesenjangan riset yang masih terbuka.

Fase kedua adalah tahap perancangan dan pengembangan sistem IoT. Pada tahap ini dilakukan perancangan arsitektur perangkat keras dan perangkat lunak dengan pendekatan *Rapid Application Development* (RAD) (Beynon-Davies et al., 1999). Metode ini dipilih karena memungkinkan proses pengembangan dilakukan

secara iteratif, sehingga pengujian dan penyempurnaan sistem dapat dilakukan secara bertahap selama proses implementasi.

Fase ketiga merupakan tahap implementasi lapangan dan akuisisi data. Sistem yang telah dirakit diuji pada lingkungan *semi-outdoor* dan dijalankan secara kontinu untuk mengumpulkan data lingkungan dan kelembapan tanah dalam bentuk runtun waktu. Tahap ini menjadi dasar pembentukan *dataset* yang akan digunakan dalam proses pemodelan.

Fase terakhir adalah tahap analisis dan pemodelan prediktif yang mengacu pada kerangka kerja *Cross Industry Standard Process for Data Mining* (CRISP-DM) (Schröer, Kruse and Gómez, 2021). Pada tahap ini dilakukan proses pemahaman data, prapemrosesan, pembangunan model, serta evaluasi kinerja. Dua algoritma yang dibandingkan dalam penelitian ini adalah *Random Forest* dan *Long Short-Term Memory* (LSTM), dengan fokus pada kemampuan masing-masing dalam memprediksi dinamika kelembapan tanah berdasarkan variabel lingkungan.

Keempat fase tersebut membentuk alur penelitian yang terintegrasi, mulai dari perumusan masalah hingga evaluasi model dalam konteks sistem *Adaptive Digital Twin* yang dikembangkan.

3.3 Studi Literatur dan Identifikasi Masalah

Studi literatur dilakukan melalui penelusuran publikasi ilmiah pada rentang tahun 2020-2026 yang relevan dengan pengembangan sistem irigasi presisi. Kajian difokuskan pada tiga aspek utama, yaitu implementasi *Internet of Things* (IoT) pada sistem irigasi, penerapan algoritma pembelajaran mesin untuk data runtun waktu, serta integrasi konsep *Digital Twin* dalam konteks *Smart Agriculture*. Analisis

terhadap ketiga aspek tersebut bertujuan untuk memahami kecenderungan pendekatan yang berkembang sekaligus mengidentifikasi ruang perbaikan yang masih terbuka.

Hasil kajian menunjukkan bahwa sebagian besar sistem irigasi berbasis IoT masih menggunakan pendekatan reaktif, umumnya berupa mekanisme ambang batas atau klasifikasi sederhana. Keputusan penyiraman dilakukan berdasarkan kondisi kelembapan tanah pada saat tertentu tanpa mempertimbangkan dinamika perubahan lingkungan dalam periode waktu berikutnya (Tace et al., 2022). Pendekatan ini relatif mudah diimplementasikan, namun kurang adaptif terhadap fluktuasi lingkungan harian.

Dari sisi pemodelan prediktif, variabel yang digunakan umumnya terbatas pada suhu dan kelembapan udara (Custódio and Prati, 2024; Kandamali et al., 2025a). Integrasi intensitas cahaya sebagai indikator radiasi matahari yang berperan dalam proses evapotranspirasi masih belum banyak diterapkan, khususnya pada sistem mandiri berbiaya rendah. Padahal, secara fisiologis variabel tersebut memiliki keterkaitan langsung dengan laju kehilangan air pada media tanam.

Permasalahan lain muncul pada aspek arsitektur sistem. Implementasi *Digital Twin* di bidang pertanian presisi umumnya dikembangkan dengan dukungan komputasi berbasis *cloud* (Bautista, Gallegos and Lampayan, 2025; Parewai and Köppen, 2025). Meskipun pendekatan ini menawarkan kapasitas pemrosesan yang besar, ketergantungan terhadap konektivitas internet berpotensi menimbulkan kendala latensi dan keterbatasan akses jaringan, terutama pada area budidaya yang tidak memiliki infrastruktur komunikasi yang stabil (Choudhary et al., 2025).

Selain itu, kajian komparatif mengenai efektivitas algoritma *Deep Learning* seperti *Long Short-Term Memory* (LSTM) dibandingkan dengan model *ensemble* yang lebih ringan seperti *Random Forest* pada lingkungan IoT berdaya terbatas masih relatif terbatas. Belum banyak penelitian yang mengevaluasi apakah peningkatan akurasi dari model yang lebih kompleks sebanding dengan kebutuhan komputasinya ketika diterapkan pada sistem *edge computing* (Bautista, Gallegos and Lampayan, 2025). Hal ini memunculkan urgensi untuk merancang arsitektur terdistribusi yang mampu menjembatani keterbatasan mikrokontroler dengan kebutuhan pemrosesan data tingkat tinggi.

Berdasarkan temuan tersebut, penelitian ini diarahkan pada pengembangan *Adaptive Digital Twin* yang diimplementasikan pada arsitektur komputasi terdistribusi (*Cloud-Edge IoT*). Sistem dirancang dengan mengintegrasikan variabel intensitas cahaya dalam proses pemodelan serta melakukan evaluasi komparatif antara *Random Forest* dan LSTM. Pendekatan ini diharapkan dapat menghasilkan mekanisme kontrol irigasi yang akurat, efisien, dan adaptif terhadap perubahan kondisi lingkungan.

3.4 Pengembangan Sistem IoT (Metode RAD)

Pengembangan purwarupa perangkat keras dan perangkat lunak pada penelitian ini mengadopsi metode *Rapid Application Development* (RAD). RAD merupakan model pengembangan sistem yang menekankan siklus pengembangan singkat, bersifat iteratif, serta melibatkan umpan balik pengguna secara berkelanjutan untuk mempercepat proses pembangunan sistem tanpa mengorbankan kualitas fungsional (Beynon-Davies et al., 1999).

Metode RAD dipilih karena sesuai dengan karakteristik pengembangan sistem *Internet of Things* (IoT) yang membutuhkan proses integrasi perangkat keras, perangkat lunak, dan jaringan secara cepat serta fleksibel. Pendekatan ini juga telah diterapkan secara efektif pada penelitian sistem irigasi cerdas sebagaimana dilaporkan oleh (Nalendra, 2021). Tahapan RAD yang diterapkan dalam penelitian ini meliputi:

3.4.1 Requirements Planning

Tahap ini berfokus pada penentuan kebutuhan dan spesifikasi teknis sebagai dasar pembangunan sistem, baik dari sisi perangkat keras maupun perangkat lunak. Perancangan dilakukan dengan menggunakan mikrokontroler ESP32 sebagai unit pemrosesan utama yang berperan sebagai perangkat *edge node* yang murni difokuskan untuk mengelola akuisisi dan pengiriman data.


Komponen sensor yang digunakan meliputi DHT22 untuk mengukur suhu dan kelembapan udara, BH1750 untuk mengukur intensitas cahaya dalam satuan lux, serta sensor kelembapan tanah kapasitif untuk memperoleh data kadar air tanah. Pemilihan kombinasi sensor ini bertujuan untuk merepresentasikan kondisi lingkungan yang memengaruhi dinamika kelembapan tanah secara lebih komprehensif.

Selain itu, digunakan unit aktuator berupa modul *relay* yang terhubung dengan pompa air mini untuk mendukung proses irigasi otomatis. Pada sisi perangkat lunak, ditetapkan kebutuhan sistem yang mencakup pemrograman mikrokontroler, infrastruktur *cloud database* (ThingSpeak) sebagai penyimpanan data *time-series*,

server Python sebagai pengesekusi model prediksi, serta pengembangan *dashboard* IoT (Blynk) untuk pemantauan dan penerimaan sinyal aktuasi.

3.4.2 User Design

Tahap *user design* mencakup perancangan arsitektur sistem secara keseluruhan, baik dari sisi perangkat keras maupun antarmuka pengguna. *Wiring diagram* disusun untuk memastikan keterhubungan antara sensor dan ESP32 berjalan dengan baik dan stabil. Selain itu, pada tahap ini juga dirancang *dashboard* IoT yang berfungsi sebagai antarmuka visualisasi *Digital Twin* untuk memantau kondisi lingkungan secara *real-time*.



Gambar 3.3 Skema Rangkaian (*Wiring Diagram*) Sistem

3.4.3 Construction

Tahap *construction* meliputi proses perakitan perangkat keras sesuai dengan rancangan yang telah dibuat. Pada tahap ini dilakukan penanaman kode program (*firmware*) ke dalam mikrokontroler ESP32 untuk menangani pembacaan data sensor dan pengiriman data ke basis data. Sistem diprogram untuk merekam data mentah sensor secara periodik tanpa pemrosesan matriks *Machine Learning* yang kompleks di sisi perangkat keras, melainkan menyerahkan beban komputasi tersebut kepada *script* Python yang berjalan di sisi server.

3.4.4 Cutover

Tahap *cutover* merupakan tahap pengujian awal sistem pada lingkungan operasional. Pengujian ini bertujuan untuk memastikan kestabilan konektivitas, konsistensi pembacaan sensor, serta kesiapan sistem sebelum digunakan dalam proses pengumpulan data penelitian.

3.5 Skenario Pengujian dan Akuisisi Data

Setelah sistem dinyatakan berfungsi dengan baik, penelitian dilanjutkan ke tahap akuisisi data. Pengujian dilakukan di lingkungan *semi-outdoor* selama 30 hari menggunakan dua unit sampel tanaman cabai rawit (*Capsicum frutescens*). Pemilihan tanaman ini didasarkan pada sensitivitas fisiologisnya terhadap variasi ketersediaan air tanah (*water stress*). Studi oleh (Utami et al., 2025) menunjukkan bahwa tanaman *Capsicum* memberikan respons fisiologis yang signifikan terhadap perubahan ketersediaan air, sehingga relevan digunakan sebagai indikator biologis dalam evaluasi kinerja sistem irigasi presisi.

Objek penelitian ditanam pada media dengan dua perlakuan berbeda, yaitu Pot A (tanah dengan campuran kompos rasio 1:1) dan Pot B (tanah non-kompos yang berkarakteristik latosol). Variasi media tanam ini bertujuan untuk menciptakan perbedaan karakteristik fisik tanah, khususnya densitas tanah (*bulk density*) dan kapasitas menahan air. (Al-Mattarneh et al., 2025) menjelaskan bahwa variasi tekstur dan kerapatan tanah merupakan faktor penting yang memengaruhi permitivitas dielektrik pada sensor kapasitif, sehingga perlu dipertimbangkan dalam pengujian model prediksi berbasis data sensor.

Tanah yang digunakan sebagai media tanam diambil dari wilayah Kota Tasikmalaya, dengan karakteristik morfologi berupa warna merah kecoklatan dan tekstur lempung berliat (*clay loam*). Berdasarkan karakteristik fisik tersebut, tanah ini memiliki kemiripan dengan tanah latosol yang umum ditemukan di wilayah tropis dan memiliki sistem drainase yang relatif baik. Karakteristik ini dinilai representatif untuk studi dinamika kelembapan tanah pada lahan pertanian lahan kering.

Proses pengumpulan data dibagi menjadi dua fase berdasarkan siklus pengeringan tanah (*dry-down cycle*), yaitu:

3.5.1 Fase 1 (Hari ke-1–15)

Tanaman disiram hingga kondisi jenuh, kemudian dibiarkan mengering secara alami. Data deret waktu (*time-series*) yang diperoleh pada fase ini digunakan sebagai *dataset* pelatihan (*training set*).

3.5.2 Fase 2 (Hari ke-16–30)

Pada hari ke-16 dilakukan penyiraman ulang (*rewetting*). Data yang dikumpulkan pada fase ini digunakan sebagai *dataset* pengujian (*testing set*) untuk mengevaluasi kemampuan model dalam memprediksi pola data baru yang bersifat dinamis.

3.6 Pemodelan Prediksi (Metode CRISP-DM)

Pengolahan data dan pembangunan model prediksi dalam penelitian ini mengacu pada kerangka kerja *Cross-Industry Standard Process for Data Mining* (CRISP-DM). CRISP-DM merupakan metodologi standar industri yang menyediakan alur sistematis dalam perencanaan, pembangunan, dan evaluasi model *data mining* untuk menghasilkan solusi yang reliabel (Schröer, Kruse and Gómez, 2021).

Pemilihan CRISP-DM didasarkan pada fleksibilitasnya dalam menangani data kompleks, serta kemampuannya dalam mengarahkan evaluasi model prediktif secara komprehensif dan sistematis (Solano et al., 2021).

3.6.1 Business Understanding

Tujuan utama penelitian ini adalah meningkatkan efisiensi penggunaan air irigasi melalui prediksi kelembapan tanah yang akurat. Hipotesis yang diuji dalam penelitian ini adalah bahwa penambahan variabel intensitas cahaya dan informasi historis kelembapan tanah dapat meningkatkan kinerja model prediksi, khususnya pada algoritma LSTM.

3.6.2 Data Understanding

Data yang diperoleh dari sistem IoT berbentuk data runtun waktu (*time-series*).

Data tersebut diklasifikasikan menjadi:

- a. Variabel Target (Y): Kelembapan tanah saat ini (t).
- b. Variabel *Input* (X):
 - 1) Suhu udara ($^{\circ}\text{C}$),
 - 2) Kelembapan udara (%)
 - 3) Intensitas cahaya (Lux)
 - 4) Waktu Pengambilan Data (jam)
 - 5) Data Historis Kelembapan ($t - 1$): Nilai kelembapan tanah pada interval waktu sebelumnya (*Lag Features*).

3.6.3 Data Preparation

Tahap *Data Preparation* merupakan fase krusial sebelum proses pemodelan. (Solano et al., 2021) menekankan bahwa kualitas data memiliki pengaruh langsung terhadap akurasi dan stabilitas model prediksi. Oleh karena itu, tahap ini dilakukan secara sistematis dengan mengacu pada teknik *preprocessing* yang direkomendasikan oleh (Ortiz et al., 2024). Proses *data preparation* yang diterapkan meliputi:

- a. Kalibrasi Sensor (Pendekatan Empiris)

Data mentah sensor kelembapan tanah dikonversi menjadi nilai kelembapan relatif (0–100%) menggunakan metode *binning* dan *smoothing interpolation* (Savitzky-Golay) sebagai bentuk kalibrasi berbasis data.

b. Signal Smoothing

Filter Savitzky-Golay diterapkan untuk mereduksi *noise* tanpa menghilangkan tren utama data.

c. Normalization dan Windowing

Data dinormalisasi ke rentang 0–1 dan disusun dalam bentuk sekuens waktu (*sliding window*) agar sesuai dengan kebutuhan *input* model LSTM.

3.6.4 Modelling

Pada tahap *Modelling*, dua algoritma *Machine Learning* dengan karakteristik yang berbeda dibangun dan dilatih menggunakan *dataset* yang telah melalui proses *preprocessing*. Tujuan tahap ini adalah melakukan komparasi kinerja antara model yang relatif ringan dan model dengan kompleksitas tinggi, yaitu:

a. *Random Forest* (RF)

Digunakan sebagai model *ensemble learning* berbasis *decision tree* yang berfungsi sebagai *baseline* karena sifatnya yang *robust* terhadap *noise* dan mudah diimplementasikan.

b. *Long Short-Term Memory* (LSTM)

Digunakan sebagai model *Deep Learning* yang diusulkan untuk menangkap ketergantungan temporal jangka panjang (*long-term dependencies*) pada data runtun waktu kelembapan tanah.

3.6.5 Evaluation

Tahap *Evaluation* dilakukan untuk menilai dan membandingkan kinerja kedua model sebelum implementasi ke dalam sistem. Sesuai dengan prosedur model

assessment yang dijelaskan oleh (Solano et al., 2021), evaluasi dilakukan menggunakan data uji pada Fase 2 dengan metode *Rolling Origin Evaluation*.

Kinerja model *Random Forest* dan LSTM dievaluasi menggunakan metrik *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan Koefisien Determinasi (R^2). Model terbaik ditentukan berdasarkan nilai error terendah dan nilai R^2 yang paling mendekati 1.