

BAB I PENDAHULUAN

1.1 Latar Belakang

Sektor pertanian merupakan salah satu sektor ekonomi terpenting di Indonesia. Pada tahun 2024 sendiri, sektor ini berkontribusi sekitar 12% hingga 14% terhadap produk domestik bruto (PDB) negara[1]. Namun, sektor ini menghadapi tantangan serius akibat pemanasan global. Catatan BMKG menunjukkan bahwa beberapa tahun terakhir merupakan tahun terpanas sepanjang sejarah pengamatan di Indonesia dengan suhu rata-rata $27,5^{\circ}\text{C}$ dan anomali sebesar $0,8^{\circ}\text{C}$ [2]. Kondisi ini menyebabkan lingkungan pertanian menjadi semakin dinamis dan sulit diprediksi, sehingga meningkatkan risiko terhadap pertumbuhan dan produktivitas tanaman. Berdasarkan laporan pemantauan cuaca dan data Badan Pusat Statistik (BPS) pada tahun 2023, kekeringan meteorologis yang berkepanjangan telah menyebabkan lebih dari 23.400 hektar lahan sawah terdampak kekeringan, dengan hampir 7.000 hektar di antaranya mengalami gagal panen total (puso) hanya dalam waktu satu bulan [3].

Dalam kondisi lingkungan yang tidak stabil seperti ini, pendekatan pertanian konvensional yang masih bergantung pada pengalaman dan observasi manual mulai menunjukkan keterbatasannya. Oleh karena itu, upaya yang dilakukan untuk mengatasi permasalahan ini adalah dengan melakukan sistem pertanian cerdas atau *smart farming*. Sistem pertanian cerdas mengintegrasikan teknologi modern, seperti *Internet of Things* (IoT), *cloud computing*, dan *machine learning* untuk menciptakan sistem pertanian yang lebih efisien dan berkelanjutan [4]. Melalui sensor IoT, berbagai parameter lingkungan seperti suhu udara, kelembapan udara, kondisi cuaca, intensitas cahaya, dan curah air hujan dapat dipantau secara *realtime* dan kontinu [5].

Penerapan *smart farming* berbasis IoT memungkinkan pemantauan parameter lingkungan secara *realtime*. Namun, data yang dihasilkan oleh sensor IoT membentuk *multivariate time series* yang sangat kompleks, mengandung pola musiman, tren jangka panjang, serta fluktuasi mendadak akibat aktivitas antropogenik di perkotaan [6]. Kompleksitas ini menuntut sistem yang tidak hanya

sekadar melakukan monitoring deskriptif, tetapi juga mampu melakukan long-term forecasting untuk mendukung pengambilan keputusan proaktif, seperti penjadwalan nutrisi dan pengendalian suhu rumah tanam.

Sebagian besar sistem prediksi pertanian saat ini masih mengandalkan model berbasis *Recurrent Neural Network* (RNN) seperti LSTM dan GRU. Meskipun efektif untuk jangka pendek, model-model ini sering mengalami penurunan performa pada horizon prediksi yang panjang akibat masalah akumulasi *error* dan keterbatasan dalam menangkap dependensi jangka panjang secara stabil [7].

Di sisi lain, arsitektur *transformer* mulai diperkenalkan untuk mengatasi kelemahan tersebut, namun banyak varian *transformer* titik-demi-titik (*point-wise attention*) masih menghadapi kendala kompleksitas komputasi yang tinggi dan kesulitan menangkap informasi semantik lokal pada data deret waktu [8]. Selain itu, terdapat kesenjangan interpretasi, di mana hasil prediksi numerik dari model AI sering kali sulit dipahami secara langsung oleh praktisi pertanian atau petani di lapangan.

Sebagai alternatif, arsitektur *transformer* untuk time series mulai diperkenalkan karena kemampuannya dalam menangkap dependensi jangka panjang melalui mekanisme *attention*. Salah satu pendekatan terbaru dan paling signifikan adalah *Patch Time Series Transformer* (PatchTST) yang diperkenalkan oleh Nie et al. (2023). PatchTST membagi data deret waktu menjadi segmen-segmen kecil (*patch*) sebelum diproses oleh *encoder transformer*, sehingga mampu meningkatkan stabilitas prediksi jangka panjang sekaligus menurunkan kompleksitas komputasi [8]. Berdasarkan hasil eksperimen pada berbagai dataset *benchmark*, PatchTST secara konsisten mengungguli model LSTM, GRU, Informer, dan Autoformer pada horizon prediksi tinggi [9].

Berdasarkan keunggulan tersebut, penelitian ini mengadopsi PatchTST sebagai model prediksi utama untuk memodelkan data sensor IoT pertanian. Pemanfaatan PatchTST diharapkan mampu menjawab keterbatasan model-model sebelumnya serta menjadi fondasi dalam pembangunan sistem prediksi kebutuhan tanaman yang lebih akurat, adaptif, dan berorientasi jangka panjang.

Sebagai upaya validasi efektivitas model, penelitian ini menetapkan tanaman Selada Merah Keriting (*Lactuca sativa L. Var. Lollo Rossa*) sebagai objek studi

berdasarkan pertimbangan metodologis dan karakteristik biologisnya. Secara metodologis, siklus panen Selada Merah sangat singkat, yaitu 35 hingga 45 hari, jadi model *machine learning* yang dihasilkan dapat divalidasi saat selada masih pada masa pertumbuhan dari fase vegetatif hingga panen [10]. Secara biologis, tanaman ini memiliki rentang suhu pertumbuhan optimal yang optimal pada 15°C hingga 25°C, Mengingat lokasi penelitian berada di wilayah Kota Bandung yang kian terdampak anomali suhu dan fenomena *Urban Heat Island* (UHI), Kondisi krisis termal ini menuntut adanya penerapan sistem prediksi PatchTST yang presisi untuk memberikan peringatan dini serta rekomendasi mitigasi risiko sebelum tanaman melampaui batas toleransi yang berujung pada gagal panen [11][12]

Selanjutnya, tantangan yang perlu dihadapi di penelitian ini adalah untuk mengintegrasikan hasil data dengan *Large Language Model* (LLM) sebagai lapisan interpretasi akhir. LLM berfungsi untuk memproses data numerik dari model PatchTST dan menyusunnya menjadi bentuk rekomendasi berbasis teks yang mudah dipahami. Integrasi ini bertujuan agar sistem menjadi prediktif dan preskriptif.

Berdasarkan urgensi dan peluang teknologi tersebut, penelitian ini mengangkat judul 'Implementasi Model *Patch Time Series Transformer* (PatchTST) untuk Prediksi Kondisi dan Kebutuhan Tumbuhan' sebagai sebuah solusi untuk presisi prediksi kebutuhan tanaman.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan di atas, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana mengimplementasikan model PatchTST untuk memprediksi kondisi lingkungan tanaman dengan *long-term forecasting* menggunakan data yang diolah dari dataset historis?
2. Bagaimana kinerja sistem model PatchTST dalam akurasi dan stabilitas prediksi berdasarkan metrik evaluasi MAE (*Mean Absolute Error*), MSE (*Mean Squared Error*), RMSE (*Root Mean Squared Error*), dan *Mean Accuracy*?

3. Bagaimana membuat sistem rekomendasi berbasis hasil prediksi PatchTST dengan mengintegrasikan *Large Language Model* (LLM) untuk memberikan rekomendasi, saran, dan tindakan yang perlu dilakukan terhadap lingkungan?

1.3 Batasan Masalah

Berdasarkan rumusan masalah yang telah diuraikan, penelitian ini dibatasi pada beberapa hal berikut.

1. Penelitian ini difokuskan pada pengembangan dan evaluasi model prediksi time series berbasis PatchTST menggunakan data historis, data yang didapatkan dari IoT hanya untuk perbandingan.
2. *Internet of Things* (IoT), Perancangan perangkat keras dan Perangkat lunak tidak menjadi fokus utama penelitian. Hanya menggunakan data sensor sebagai sumber input data untuk perbandingan.
3. Parameter yang digunakan meliputi suhu udara, kelembapan, intensitas cahaya, presipitasi, dan cuaca, faktor eksternal seperti cuaca ekstrem, gangguan jaringan internet tidak akan dianalisis sebagai variabel utama dalam penelitian ini.
4. Sistem yang dibangun tidak mencakup pengendalian otomatis seperti irigasi otomatis, pemupukan otomatis, atau pengaturan suhu otomatis, melainkan hanya menghasilkan hasil prediksi dan rekomendasi tindakan kepada pengguna.
5. Penggunaan LLM dibatasi pada pemanfaatan model *pre-trained* local menggunakan QWEN 2.5/14B dengan metode *prompt engineering*. Penelitian ini tidak mencakup pembuatan atau *fine-tuning foundation* model dari awal.

1.4 Tujuan

Berdasarkan latar belakang dan rumusan masalah yang telah dipaparkan, tujuan dilakukannya penelitian ini adalah sebagai berikut:

1. Membangun model Patch Time Series Transformer (PatchTST) untuk memprediksi kondisi lingkungan tanaman secara long-term forecasting menggunakan data multivariat yang diolah dari dataset historis.
2. Mengevaluasi kinerja model prediksi yang dikembangkan menggunakan metrik evaluasi MAE (*Mean Absolute Error*), MSE (*Mean Squared Error*), RMSE (*Root Mean Squared Error*), dan *Mean Accuracy*.

3. Mengembangkan sistem rekomendasi dari hasil prediksi model PatchTST dengan mengintegrasikan *Large Language Model* (LLM) agar memberikan rekomendasi, saran, dan tindakan yang perlu dilakukan.

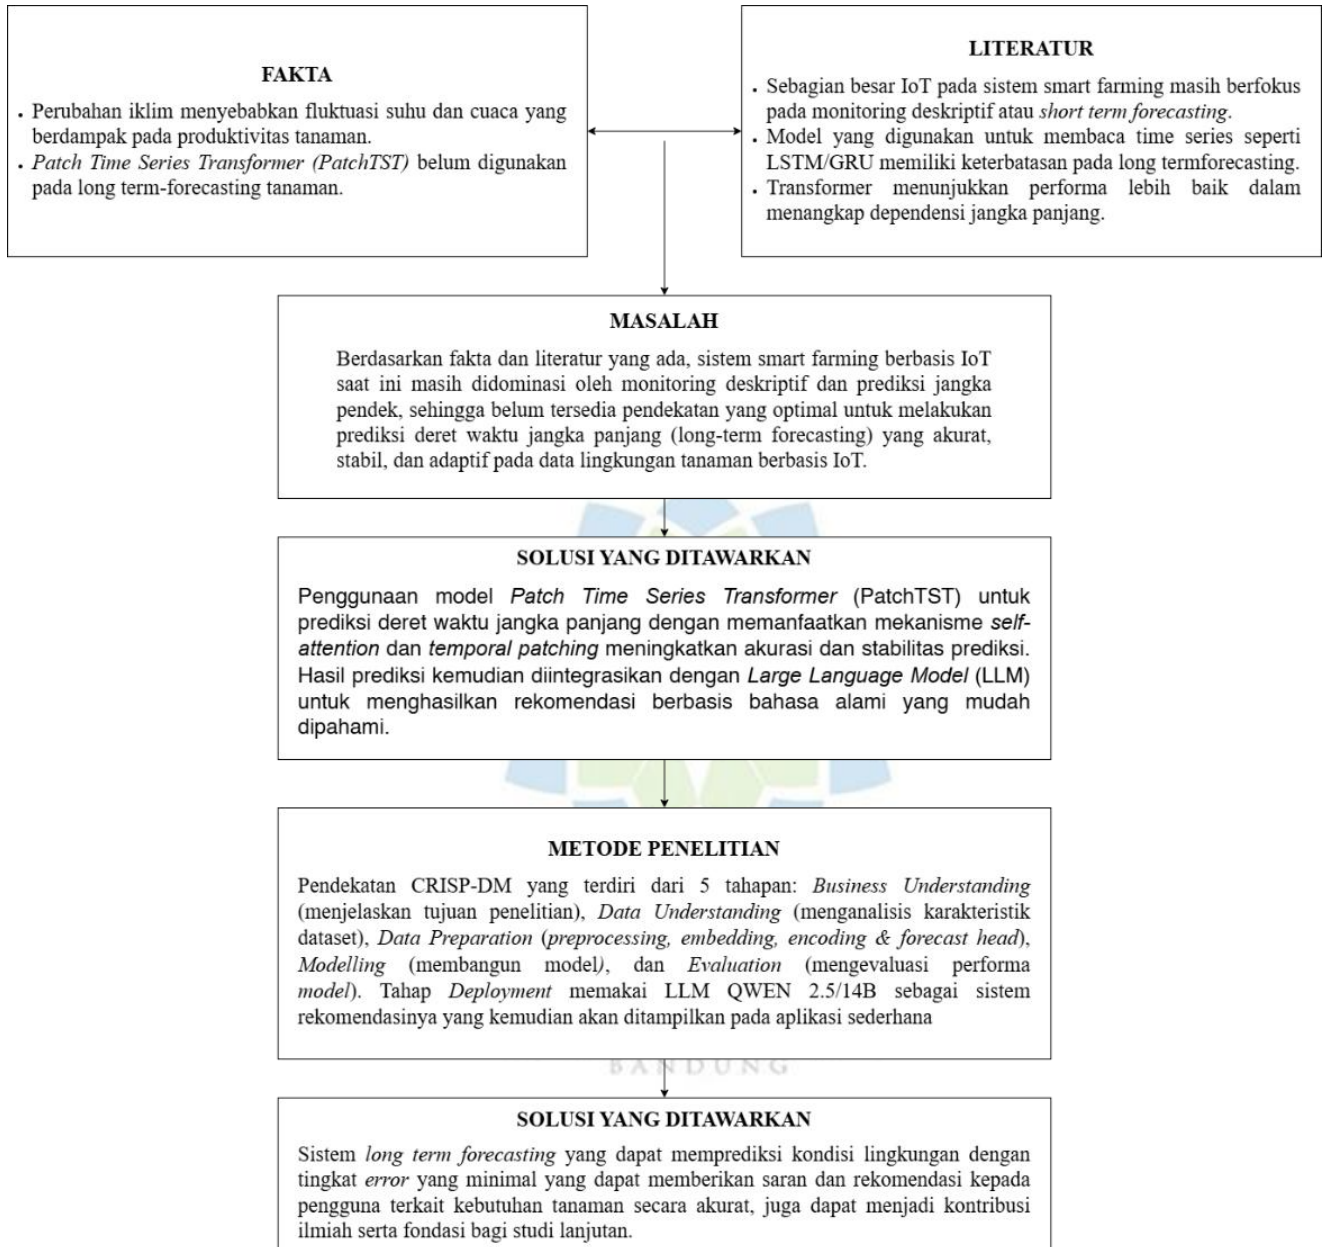
1.5 Manfaat

Dengan tulisan ini, penulis mengharapkan penelitian ini memiliki manfaat sebagai berikut:

1. Menghasilkan sistem *long-term forecasting* yang mampu memberikan prediksi kondisi lingkungan dengan stabil.
2. Menghasilkan *prototype* sistem yang dapat diadopsi dan dikembangkan lebih lanjut pada sektor pertanian.
3. Memberikan kontribusi ilmiah dalam penerapan *Patch Time Series Transformer* (PatchTST).



1.6 Kerangka Pemikiran



Gambar 1.1 Kerangka Pemikiran Penelitian

Berdasarkan informasi yang ditampilkan pada gambar 1.1, Penelitian ini diinisiasi berdasarkan pengamatan lapangan yang menunjukkan bahwa fenomena perubahan iklim telah memicu fluktuasi suhu dan cuaca ekstrem yang berdampak buruk pada produktivitas tanaman. Meskipun kebutuhan akan sistem peringatan dibutuhkan, penggunaan algoritma-algoritma seperti PatchTST masih belum dioptimalkan untuk tugas *long-term forecasting* pada data lingkungan pertanian.

Berdasarkan tinjauan terhadap sistem pertanian cerdas saat ini, sebagian besar teknologi IoT masih terpaku pada fungsi monitoring deskriptif atau *short-term forecasting* yang bersifat reaktif [13]. Di sisi lain, model-model yang digunakan sekuensial konvensional seperti LSTM dan GRU memiliki keterbatasan dalam menangkap dependensi jangka panjang, yang mengakibatkan akumulasi kesalahan pada prediksi masa depan. Kondisi ini menyebabkan belum tersedianya pendekatan prediktif yang benar-benar akurat, stabil, dan adaptif untuk mengolah data lingkungan tanaman berbasis IoT [14].

Untuk menjawab permasalahan tersebut, penelitian ini mengusulkan implementasi arsitektur PatchTST untuk peramalan jangka panjang dengan memanfaatkan mekanisme *temporal patching* dan *self-attention* guna meningkatkan presisi model. Hasil analisis numerik tersebut kemudian diintegrasikan dengan *large language model* (LLM) Qwen2.5/14B yang berfungsi untuk mengubah data prediksi menjadi teks rekomendasi tindakan dalam bahasa yang mudah dipahami. Alur kerja riset ini mengadaptasi siklus metodologi *CRISP-DM* yang dibatasi pada lima fase utama: *business understanding*, *data understanding*, *data preparation*, *modelling*, *evaluation*, dan *deployment*.

Sistem yang dikembangkan diharapkan mampu menyajikan proyeksi kondisi lingkungan dengan tingkat *error* minimal serta memberikan panduan kebutuhan tanaman yang akurat bagi petani. Selain memberikan manfaat praktis dalam menjaga stabilitas panen, luaran penelitian ini diproyeksikan menjadi kontribusi ilmiah yang signifikan sekaligus menjadi fondasi teknis bagi pengembangan studi lanjutan di bidang pertanian digital masa depan.

1.7 Sistematika Penulisan

Berikut Sistematika Penulisan pada penelitian ini yang disusun secara terstruktur:

BAB I PENDAHULUAN

Bab ini Terdiri dari latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, kerangka berpikir, dan sistematika penulisan.

BAB II STUDI PUSTAKA

Pada bab ini membahas terkait literatur atau penelitian terdahulu, konsep-konsep, teori-teori, model, dan rumus yang menjadi landasan dalam proses analisis permasalahan dengan topik masalah yang diambil.

BAB III METODOLOGI PENELITIAN

Menjelaskan tentang metodologi penelitian yang berisi langkah-langkah dan teknik yang diterapkan dalam penelitian, diuraikan secara sistematis dan terstruktur.

BAB IV HASIL DAN PEMBAHASAN

Bab ini memaparkan dua hal utama yaitu pemaparan tentang temuan dan hasil penelitian berdasarkan langkah-langkah penelitian yang telah dilakukan. Selanjutnya adalah pembahasan hasil atau temuan penelitian sebagai jawaban terhadap rumusan masalah penelitian.

BAB V PENUTUP

Bab ini fokus pada penarikan kesimpulan dari hasil penelitian yang diperoleh serta menjawab pertanyaan yang ditanyakan di rumusan masalah penelitian ini. Selain itu bab ini memberikan saran untuk penelitian selanjutnya yang dapat dilakukan agar meningkatkan kualitas dari penelitian tersebut.