



Prediksi Time Series Permukaan Air Sungai Menggunakan Long Short-Term Memory-Autoregressive Integrated Moving Average

Norita Febriyanti*, Michael Ardita, I Komang Somawirata

Teknik Elektro, Institut Teknologi Nasional Malang, Malang, Indonesia

Email: ^{1,*}noritafbrynt@gmail.com, ²michael.ardita@lecturer.itn.ac.id, ³kmgssomawirata@lecturer.itn.ac.id

Email Penulis Korespondensi: noritafbrynt@gmail.com

Abstrak—Prediksi ketinggian permukaan air sungai merupakan komponen penting dalam sistem peringatan dini banjir karena mampu memberikan informasi mengenai potensi kenaikan muka air sebelum terjadi luapan. Sungai Kebonagung, Kabupaten Sumenep, dipilih sebagai lokasi penelitian karena memiliki fluktuasi tinggi muka air yang dipengaruhi oleh perubahan debit dan volume air sehingga memerlukan model prediksi yang mampu menangkap pola linier maupun nonlinier. Metode ARIMA efektif untuk memodelkan pola deret waktu yang linier dan musiman, sedangkan LSTM mampu menangkap pola nonlinier serta ketergantungan jangka panjang dengan akurasi yang tinggi. Penelitian ini bertujuan membandingkan tiga pendekatan, yaitu Long Short-Term Memory (LSTM), ARIMA pada variabel debit yang diintegrasikan dengan LSTM, serta Hybrid Autoregressive Integrated Moving Average–Long Short-Term Memory (ARIMA-LSTM) untuk memprediksi ketinggian permukaan air sungai berdasarkan data historis selama satu tahun dengan interval pengamatan satu jam yang terdiri atas variabel tinggi muka air, debit, dan volume air. Kinerja model dievaluasi menggunakan Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Hasil pengujian menunjukkan bahwa model LSTM menghasilkan RMSE 128,15, MAE 96,61, dan MAPE 3,56%, sedangkan model ARIMA (debit)-LSTM memperoleh RMSE 127,63, MAE 96,33, dan MAPE 3,55%. Model Hybrid ARIMA-LSTM menghasilkan RMSE terendah sebesar 127,06, namun nilai MAE dan MAPE sedikit lebih tinggi, yaitu masing-masing 96,81 dan 3,59%. Temuan ini menunjukkan bahwa integrasi ARIMA dan LSTM mampu mengurangi kesalahan prediksi yang besar sehingga menghasilkan RMSE yang lebih rendah, tetapi peningkatan performanya terhadap model lain belum signifikan karena seluruh model memiliki tingkat kesalahan yang relatif berdekatan. Oleh karena itu, model Hybrid lebih tepat dipandang sebagai pendekatan yang meningkatkan stabilitas prediksi dibandingkan memberikan peningkatan akurasi yang besar. Kontribusi penelitian ini terletak pada evaluasi dua strategi integrasi ARIMA dan LSTM, yaitu penggunaan hasil prediksi debit ARIMA sebagai fitur masukan LSTM serta pendekatan Hybrid ARIMA-LSTM berbasis residual, menggunakan dataset hidrologi yang sama sehingga karakteristik, kelebihan, dan keterbatasan masing-masing pendekatan dapat dibandingkan secara objektif. Temuan ini diharapkan menjadi referensi dalam pengembangan model prediksi tinggi muka air sungai untuk mendukung sistem peringatan dini banjir berbasis *time series*.

Kata Kunci: Time Series; Prediksi Ketinggian Air Sungai; Long Short-Term Memory (LSTM); Auto Regresive Integrated Moving Average (ARIMA)

Abstract—River water level prediction is an essential component of flood early warning systems, as it provides information on potential water level increases before overflow occurs. The Kebonagung River in Sumenep Regency was selected as the study area due to its fluctuating water levels, which are influenced by variations in river discharge and water volume, thereby requiring a prediction model capable of capturing both linear and nonlinear patterns. The Autoregressive Integrated Moving Average (ARIMA) model is effective in modeling linear and seasonal time-series patterns, whereas the Long Short-Term Memory (LSTM) model is capable of learning nonlinear relationships and long-term temporal dependencies with high accuracy. This study aims to compare three prediction approaches: Long Short-Term Memory (LSTM), ARIMA-based discharge integrated with LSTM, and the Hybrid Autoregressive Integrated Moving Average–Long Short-Term Memory (ARIMA-LSTM) model for predicting river water levels using one year of historical data collected at one-hour intervals, consisting of water level, discharge, and water volume variables. Model performance was evaluated using Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE). The experimental results show that the LSTM model achieved an RMSE of 128.15, an MAE of 96.61, and a MAPE of 3.56%, while the ARIMA (discharge)-LSTM model obtained an RMSE of 127.63, an MAE of 96.33, and a MAPE of 3.55%. The Hybrid ARIMA-LSTM model produced the lowest RMSE of 127.06, although its MAE and MAPE were slightly higher at 96.81 and 3.59%, respectively. These findings indicate that integrating ARIMA and LSTM can reduce large prediction errors, resulting in a lower RMSE; however, the performance improvement over the other models is not substantial because all models exhibit relatively similar error levels. Therefore, the Hybrid ARIMA-LSTM model is better regarded as an approach that improves prediction stability rather than one that delivers a significant increase in predictive accuracy. The main contribution of this study lies in the evaluation of two ARIMA-LSTM integration strategies, namely the use of ARIMA-based discharge predictions as input features for the LSTM model and a residual-based Hybrid ARIMA-LSTM approach, using the same hydrological dataset to enable an objective comparison of the characteristics, strengths, and limitations of each approach. The findings are expected to provide a useful reference for the development of river water level prediction models to support time-series-based flood early warning systems.

Keywords: Time Series; River Water Level Prediction; Long Short-Term Memory (LSTM); Auto Regresive Integrated Moving Average (ARIMA)

1. PENDAHULUAN

Banjir dapat disebabkan oleh faktor alami maupun buatan, namun dalam kedua skenario tersebut manusia turut bertanggung jawab atas kerusakan yang terjadi[1]. Banjir dapat diartikan sebagai kondisi aliran air yang tidak lagi mampu ditampung oleh alur sungai atau sistem saluran yang ada. Sungai memiliki peranan penting sebagai sumber kehidupan bagi masyarakat yang bermukim di sepanjang bantaran sungai maupun di wilayah perkotaan. Saat terjadi hujan, peningkatan debit air dapat menyebabkan luapan di berbagai daerah sehingga menimbulkan genangan di sejumlah lokasi dan berpotensi mengakibatkan banjir. Untuk meminimalkan kerugian akibat genangan air tersebut, salah satu upaya yang



dapat dilakukan adalah dengan memantau ketinggian muka air secara akurat dan real time. Oleh karena itu, diperlukan pemantauan ketinggian permukaan air jarak jauh yang dapat dipantau secara real time. Dengan adanya sistem pemantauan ketinggian air tersebut, diharapkan potensi kerugian akibat ketidakseimbangan ketinggian air dapat diminimalkan serta risiko bencana yang ditimbulkan dapat dicegah[2].

Selain pemantauan, peramalan ketinggian muka air sungai sangat penting untuk mengurangi kehilangan jiwa dan harta benda. Pemantauan yang andal serta teknologi deteksi ketinggian muka air sungai yang mutakhir sangat diperlukan untuk melindungi kehidupan dan properti masyarakat yang tinggal di sekitar daerah aliran sungai. Untuk memenuhi kebutuhan tersebut, diperlukan peramalan ketinggian muka air sungai yang memiliki tingkat akurasi tinggi[1]. Metode deep learning, khususnya Long Short-Term Memory (LSTM), telah terbukti memiliki kinerja yang baik dalam memprediksi perubahan permukaan air. LSTM dirancang untuk mengolah data deret waktu yang kompleks dan mampu meningkatkan akurasi prediksi dengan mengenali pola jangka panjang yang tidak dapat diidentifikasi oleh metode konvensional[3].

Penelitian yang dilakukan menerapkan metode LSTM dalam memprediksi ketinggian muka air sungai dan memperoleh hasil yang sangat baik dalam merepresentasikan dinamika temporal pada data hidrologi. Keunggulan LSTM dibandingkan dengan model Recurrent Neural Network (RNN) lainnya terletak pada kemampuannya dalam menangani permasalahan ketergantungan jangka panjang (long-term dependencies) pada data berurutan. Hal ini dimungkinkan karena LSTM dilengkapi dengan mekanisme gate yang berfungsi mengatur aliran informasi sehingga konteks temporal yang penting dapat dipertahankan dalam rentang waktu yang panjang [4].

Selain pemodelan ketinggian muka air sungai menggunakan pendekatan deep learning, diperlukan pendekatan statistik yang dapat memodelkan pengaruh musiman debit sungai, di mana salah satu metode yang digunakan adalah ARIMA (Autoregressive Integrated Moving Average)[5]. ARIMA merupakan model statistik yang digunakan untuk menganalisis dan memprediksi data deret waktu dengan pola linier. ARIMA digunakan untuk data yang memiliki tren jangka panjang dan tidak terlalu dipengaruhi oleh hubungan nonlinier yang kompleks[6]. Adapun beberapa konsep dasar ARIMA antara lain, pengidentifikasian model, penaksiran parameter, pemeriksaan diagnostik, dan peramalan[7].

Masing-masing model memiliki pendekatan yang berbeda dalam menganalisis data. ARIMA mengandalkan hubungan linier dalam data deret waktu, sementara LSTM menggunakan teknik pembelajaran mendalam untuk menangkap pola yang lebih kompleks dan nonlinier[6]. Oleh sebab itu, penggunaan ARIMA sebagai pendamping LSTM diharapkan dapat saling melengkapi sehingga masing-masing metode bekerja pada karakteristik data yang paling sesuai.

Secara hidrologi, tinggi muka air sungai memiliki hubungan yang erat dengan debit aliran dan volume air. Debit menggambarkan jumlah aliran air yang melewati suatu penampang sungai dalam satuan waktu, sedangkan volume air merepresentasikan akumulasi air yang tersimpan pada suatu kondisi tertentu. Perubahan debit umumnya akan diikuti oleh perubahan tinggi muka air[8]. Oleh karena itu, penggunaan variabel debit dan volume sebagai fitur masukan diharapkan mampu memberikan informasi tambahan yang lebih representatif bagi model LSTM dalam mempelajari dinamika perubahan tinggi muka air sungai.

Penelitian terkait prediksi muka air sungai telah banyak dilakukan dengan berbagai pendekatan, baik menggunakan metode statistik, machine learning, maupun deep learning. Beberapa penelitian terdahulu yang relevan dengan penelitian ini dapat dijelaskan sebagai berikut.

F. I. Maulana & Hakim (2023) melakukan penelitian Estimasi Tinggi Muka Air Menggunakan Metode Neural Network pada Wilayah Hilir Pos Brangkal bertujuan untuk mengestimasi tinggi muka air sungai di wilayah hilir Pos Brangkal, Kabupaten Bojonegoro, sebagai upaya mitigasi banjir dan pengelolaan sumber daya air. Metode yang digunakan adalah Artificial Neural Network (ANN) dengan variabel klimatologi, serta output berupa tinggi muka air sungai. Data yang digunakan merupakan data historis selama 2,5 tahun yang diperoleh dari BBWS Bengawan Solo. Hasil penelitian menunjukkan bahwa model Neural Network mampu menghasilkan performa estimasi yang baik dengan nilai MSE sebesar 1,77 dan MAPE sebesar 2,82%, yang mengindikasikan tingkat kesalahan prediksi yang sangat rendah. Hal ini menunjukkan bahwa ANN efektif dalam menangkap hubungan nonlinier antara variabel klimatologi dan tinggi muka air sungai. Keterbatasan penelitian ini adalah penggunaan arsitektur Neural Network yang relatif sederhana serta tidak adanya perbandingan dengan metode lain seperti ARIMA atau LSTM. Selain itu, aspek ketergantungan temporal jangka panjang belum dimodelkan secara eksplisit [9].

Isnandi et al. (2023) melakukan penelitian Prediksi Debit Aliran Sungai Menggunakan Metode ARIMA bertujuan untuk memprediksi debit aliran Sungai Tapung Kiri dengan mempertimbangkan faktor musiman. Data yang digunakan berupa data debit sungai historis yang bersumber dari AWLR Balai Wilayah Sungai Sumatera III. Hasil analisis menunjukkan bahwa model terbaik yang diperoleh adalah ARIMA (0,1,1)(0,1,1)¹², dengan nilai MAPE sebesar 42%. Hasil ini menunjukkan bahwa meskipun ARIMA mampu menangkap pola musiman debit sungai, tingkat akurasinya masih tergolong rendah. Kelemahan utama penelitian ini adalah keterbatasan ARIMA dalam menangani hubungan nonlinier dan variabel multivariat. Selain itu, nilai kesalahan prediksi yang relatif besar menunjukkan perlunya pendekatan berbasis machine learning atau deep learning [5].

Subito et al. (2023) melakukan penelitian Rancang Bangun Sistem Monitoring Level Permukaan Air Berbasis Internet of Things (IoT) yang berfokus pada perancangan sistem monitoring ketinggian permukaan air sungai secara real-time berbasis Internet of Things (IoT). Sistem menggunakan sensor level air metode float magnetic level gauge yang terhubung dengan mikrokontroler ESP32, serta platform IoT Blynk dan Telegram sebagai media monitoring dan notifikasi. Hasil pengujian menunjukkan bahwa sistem memiliki rata-rata error pengukuran sebesar 1,5%, sehingga dinilai cukup akurat dan andal untuk pemantauan dini potensi banjir. Namun, penelitian ini tidak mencakup aspek prediksi atau

peramalan tinggi muka air. Sistem hanya bersifat monitoring real-time tanpa kemampuan analisis temporal atau forecasting, sehingga belum mendukung pengambilan keputusan jangka panjang[10].

Rais et al. (2022) melakukan penelitian mengenai prediksi kenaikan permukaan air laut di Teluk Jakarta menggunakan algoritma Long Short-Term Memory (LSTM) berbasis data satelit altimetri. Hasil penelitian menunjukkan bahwa LSTM mampu mempelajari pola temporal jangka panjang dan menghasilkan prediksi yang baik terhadap perubahan muka air laut. Namun, penelitian tersebut diterapkan pada lingkungan laut yang memiliki karakteristik hidrodinamika berbeda dengan sungai serta belum mengintegrasikan metode statistik seperti ARIMA untuk menangkap pola linier pada data *time series* [11].

Agustianto dan Purnamasari (2020) menerapkan metode ARIMA dengan deteksi *outlier* untuk memprediksi ketinggian permukaan Air Sungai Mahakam menggunakan data rata-rata bulanan. Hasil penelitian menunjukkan bahwa penambahan efek *outlier* mampu meningkatkan performa model ARIMA. Namun, penelitian tersebut hanya menggunakan pendekatan statistik univariat sehingga belum mampu memodelkan hubungan nonlinier maupun memanfaatkan variabel hidrologi lain sebagai informasi pendukung[12].


Berdasarkan penelitian terdahulu, masih terdapat beberapa kesenjangan penelitian (*research gap*). Maulana dan Hakim [9] menunjukkan bahwa Artificial Neural Network mampu menghasilkan estimasi tinggi muka air yang baik, namun belum memanfaatkan arsitektur LSTM yang lebih efektif dalam mempelajari ketergantungan temporal jangka panjang. Isnandi et al. [5] membuktikan bahwa ARIMA dapat memodelkan pola musiman debit sungai, tetapi masih memiliki keterbatasan dalam menangani hubungan nonlinier dan menghasilkan tingkat kesalahan prediksi yang relatif tinggi. Rais et al. [11] berhasil menerapkan LSTM untuk prediksi permukaan air laut, namun objek penelitian memiliki karakteristik hidrologi yang berbeda dengan sungai dan belum mengombinasikan pendekatan statistik dengan *deep learning*. Sementara itu, Agustianto dan Purnamasari [12] menggunakan ARIMA dengan deteksi *outlier* pada data ketinggian muka air sungai, tetapi model yang digunakan masih bersifat univariat sehingga belum memanfaatkan informasi dari variabel hidrologi lain seperti debit dan volume air. Oleh karena itu, penelitian ini mengusulkan integrasi ARIMA dan LSTM untuk memanfaatkan keunggulan masing-masing metode dalam memodelkan pola linier dan nonlinier, serta menggunakan variabel tinggi muka air, debit, dan volume air pada data *time series* Sungai Kebonagung. Selain itu, penelitian ini membandingkan tiga pendekatan, yaitu LSTM, ARIMA (Debit)-LSTM, dan Hybrid ARIMA-LSTM, sehingga dapat memberikan evaluasi yang lebih komprehensif terhadap performa masing-masing model dalam prediksi tinggi muka air sungai.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan jenis penelitian kuantitatif dengan metode eksperimen untuk membangun model prediksi tinggi muka air sungai berbasis data *time series*. Pendekatan eksperimental dilakukan dengan membangun, melatih, dan menguji model prediksi ketinggian muka air sungai menggunakan integrasi *deep learning* LSTM dan statistik ARIMA (Autoregressive Integrated Moving Average) berdasarkan data *time series*. Tahapan penelitian dimulai dari pengumpulan data hasil pengukuran sensor, dilanjutkan dengan proses preprocessing, pembangunan model, pelatihan model, pengujian model, hingga evaluasi performa menggunakan beberapa metrik kesalahan. Diagram blok penelitian disajikan pada Gambar dibawah ini sebagai gambaran keseluruhan proses yang dilakukan pada penelitian ini.

Berikut merupakan Diagram Blok tahapan dari penelitian ini :



Gambar 1. Diagram Blok Sistem Prediksi Air Sungai Menggunakan Arima(debit) dan LSTM

Berdasarkan Gambar 1 dapat dijelaskan beberapa tahapan Sistem Prediksi Air Sungai Menggunakan Arima(debit) dan LSTM sebagai berikut :

a. Sensor Tinggi Muka Air, Debit, dan Volume Air

Tahap pertama penelitian adalah proses akuisisi data hidrologi menggunakan sensor yang mengukur tiga parameter utama, yaitu tinggi muka air, debit air, dan volume air. Sensor melakukan pengukuran secara berkala dengan interval satu jam sehingga menghasilkan data *time series* yang menggambarkan perubahan kondisi sungai dari waktu ke waktu. Variabel tinggi muka air digunakan sebagai target prediksi, sedangkan debit dan volume air dimanfaatkan sebagai variabel pendukung karena memiliki hubungan hidrologi terhadap perubahan tinggi muka air sungai[13]. Data hasil pengukuran sensor selanjutnya dikirimkan ke mikrokontroler untuk diproses sebelum disimpan ke dalam basis data.

b. Mikrokontroler (ESP32)

Mikrokontroler ESP32 berfungsi sebagai pusat akuisisi data yang menerima hasil pengukuran dari sensor, melakukan pembacaan setiap parameter, serta mengelola proses pengiriman data ke server. ESP32 dipilih karena memiliki kemampuan pemrosesan yang baik serta telah dilengkapi modul Wi-Fi sehingga mampu mengirimkan data secara nirkabel ke basis data[14]. Pada tahap ini, data sensor diberi informasi waktu (*timestamp*) sebagai penanda waktu pengukuran sehingga urutan data tetap terjaga dan dapat digunakan sebagai data *time series*.

c. Database MySQL

Data yang telah dikirim oleh ESP32 kemudian disimpan ke dalam basis data MySQL. Penggunaan MySQL bertujuan untuk menyimpan data historis hasil pengukuran secara terstruktur sehingga memudahkan proses pengelolaan, pencarian, dan pengambilan data pada tahap analisis[15]. Setiap data yang tersimpan terdiri atas informasi waktu pengukuran (*timestamp*), tinggi muka air, debit, dan volume air. Selanjutnya, data historis tersebut diekstraksi dari database untuk dilakukan proses *preprocessing* sebelum digunakan dalam pembentukan model prediksi.


d. Tahap Preprocessing

Preprocessing data merupakan langkah untuk pembersihan data sebelum digunakan dalam proses pelatihan model[16]. dataset melalui beberapa tahapan preprocessing, yaitu:

1. Mengubah atribut waktu menjadi format datetime.
2. Menjadikan atribut waktu sebagai index dataset.
3. Mengubah seluruh atribut numerik menjadi tipe data float.
4. Mengganti nilai 0 yang dianggap data hilang (missing value) menjadi NaN.
5. Melakukan interpolasi menggunakan metode time interpolation untuk mengisi data yang hilang.
6. Menghapus data yang masih memiliki nilai kosong (drop missing value).
7. Melakukan normalisasi menggunakan metode MinMaxScaler sehingga seluruh data berada pada rentang 0–1 sebelum diproses oleh model. Proses ini dilakukan dengan mengurangi nilai minimum dari setiap fitur, mengatasi perbedaan skala variabel dan memastikan bahwa semua data berada dalam rentang yang seragam[17].

e. Pemodelan Debit Sungai menggunakan ARIMA, Data debit sungai dimodelkan menggunakan metode ARIMA untuk menangkap pola linier dan fluktuasi jangka pendek pada data *time series*. Proses pemodelan diawali dengan uji stasioneritas untuk memastikan data memenuhi asumsi ARIMA, dilanjutkan dengan penentuan parameter model yang optimal berdasarkan hasil analisis, kemudian dilakukan pelatihan dan validasi model menggunakan data historis. Hasil prediksi debit sungai yang diperoleh dari model ARIMA selanjutnya digunakan sebagai informasi tambahan (*additional feature*) pada model LSTM guna meningkatkan kemampuan model dalam mempelajari hubungan temporal antara debit dan tinggi muka air sungai.

f. Pemodelan dan Prediksi Menggunakan LSTM, Model LSTM dilatih menggunakan data historis yang telah diolah. Parameter tinggi muka air, debit(hasil pemodelan ARIMA), dan volume air digunakan sebagai variabel input, sedangkan output model berupa nilai prediksi tinggi permukaan air sungai.



Gambar 2. Diagram Blok Sistem Prediksi Air Sungai Menggunakan LSTM

Berdasarkan Gambar 2 dapat dijelaskan beberapa tahapan Sistem Prediksi Air Sungai Menggunakan LSTM sebagai berikut :

1. Sensor Tinggi Muka Air, Debit, dan Volume Air

Tahap pertama penelitian adalah proses akuisisi data hidrologi menggunakan sensor yang mengukur tiga parameter utama, yaitu tinggi muka air, debit air, dan volume air. Sensor melakukan pengukuran secara berkala dengan interval satu jam sehingga menghasilkan data *time series* yang menggambarkan perubahan kondisi sungai dari waktu ke waktu. Variabel tinggi muka air digunakan sebagai target prediksi, sedangkan debit dan volume air dimanfaatkan sebagai variabel pendukung karena memiliki hubungan hidrologi terhadap perubahan tinggi muka air sungai[13]. Data hasil pengukuran sensor selanjutnya dikirimkan ke mikrokontroler untuk diproses sebelum disimpan ke dalam basis data.

2. Mikrokontroler (ESP32)

Mikrokontroler ESP32 berfungsi sebagai pusat akuisisi data yang menerima hasil pengukuran dari sensor, melakukan pembacaan setiap parameter, serta mengelola proses pengiriman data ke server. ESP32 dipilih karena memiliki kemampuan pemrosesan yang baik serta telah dilengkapi modul Wi-Fi sehingga mampu mengirimkan data secara nirkabel ke basis data[14]. Pada tahap ini, data sensor diberi informasi waktu (*timestamp*) sebagai penanda waktu pengukuran sehingga urutan data tetap terjaga dan dapat digunakan sebagai data *time series*.

3. Database MySQL


Data yang telah dikirim oleh ESP32 kemudian disimpan ke dalam basis data MySQL. Penggunaan MySQL bertujuan untuk menyimpan data historis hasil pengukuran secara terstruktur sehingga memudahkan proses pengelolaan, pencarian, dan pengambilan data pada tahap analisis[15]. Setiap data yang tersimpan terdiri atas informasi waktu pengukuran (*timestamp*), tinggi muka air, debit, dan volume air. Selanjutnya, data historis tersebut diekstraksi dari database untuk dilakukan proses *preprocessing* sebelum digunakan dalam pembentukan model prediksi.

4. Tahap Preprocessing

Preprocessing data merupakan langkah untuk pembersihan data sebelum digunakan dalam proses pelatihan model[16]. dataset melalui beberapa tahapan preprocessing, yaitu:

- Mengubah atribut waktu menjadi format *datetime*.
- Menjadikan atribut waktu sebagai *index* dataset.
- Mengubah seluruh atribut numerik menjadi tipe data *float*.
- Mengganti nilai 0 yang dianggap data hilang (*missing value*) menjadi *NaN*.
- Melakukan interpolasi menggunakan metode *time interpolation* untuk mengisi data yang hilang.
- Menghapus data yang masih memiliki nilai kosong (*drop missing value*).
- Melakukan normalisasi menggunakan metode *MinMaxScaler* sehingga seluruh data berada pada rentang 0–1 sebelum diproses oleh model. Proses ini dilakukan dengan mengurangi nilai minimum dari setiap fitur, mengatasi perbedaan skala variabel dan memastikan bahwa semua data berada dalam rentang yang seragam[17].

- Pemodelan dan Prediksi Menggunakan LSTM, Model LSTM dibangun menggunakan empat lapisan tersembunyi (*hidden layer*) dengan jumlah neuron berturut-turut 64, 32, 16, dan 8 neuron. Fungsi aktivasi *tanh* digunakan pada sel memori LSTM, sedangkan *sigmoid* digunakan pada mekanisme *gate* untuk mengatur aliran informasi. Lapisan keluaran menggunakan fungsi aktivasi linear karena target prediksi berupa nilai kontinu. Optimizer Adam dipilih karena memiliki kemampuan adaptif dalam memperbarui bobot sehingga umum digunakan pada permasalahan prediksi *time series*. Penentuan parameter pelatihan seperti jumlah *epoch*, ukuran *batch*, jumlah neuron, serta *window size* dilakukan melalui beberapa percobaan (*trial and error*) dengan mempertimbangkan keseimbangan antara akurasi prediksi, waktu pelatihan, dan kestabilan proses konvergensi. Berdasarkan hasil percobaan tersebut diperoleh konfigurasi terbaik menggunakan *window size* 24, *batch size* 16, *learning rate* 0,001, dan jumlah *epoch* sebanyak 30.



Gambar 3. Diagram Blok Sistem Prediksi Air Sungai Menggunakan Hybrid

Berdasarkan gambar 3 dapat dijelaskan beberapa tahapan Sistem Prediksi Air Sungai Menggunakan Hybrid sebagai berikut :

1. Sensor Tinggi Muka Air, Debit, dan Volume Air

Tahap pertama penelitian adalah proses akuisisi data hidrologi menggunakan sensor yang mengukur tiga parameter utama, yaitu tinggi muka air, debit air, dan volume air. Sensor melakukan pengukuran secara berkala dengan interval satu jam sehingga menghasilkan data *time series* yang menggambarkan perubahan kondisi sungai dari waktu ke waktu. Variabel tinggi muka air digunakan sebagai target prediksi, sedangkan debit dan volume air dimanfaatkan sebagai variabel pendukung karena memiliki hubungan hidrologi terhadap perubahan tinggi muka air sungai[13]. Data hasil pengukuran sensor selanjutnya dikirimkan ke mikrokontroler untuk diproses sebelum disimpan ke dalam basis data.

2. Mikrokontroler (ESP32)

Mikrokontroler ESP32 berfungsi sebagai pusat akuisisi data yang menerima hasil pengukuran dari sensor, melakukan pembacaan setiap parameter, serta mengelola proses pengiriman data ke server. ESP32 dipilih karena memiliki kemampuan pemrosesan yang baik serta telah dilengkapi modul Wi-Fi sehingga mampu mengirimkan data secara nirkabel ke basis data[14]. Pada tahap ini, data sensor diberi informasi waktu (*timestamp*) sebagai penanda waktu pengukuran sehingga urutan data tetap terjaga dan dapat digunakan sebagai data *time series*.

3. Database MySQL

Data yang telah dikirim oleh ESP32 kemudian disimpan ke dalam basis data MySQL. Penggunaan MySQL bertujuan untuk menyimpan data historis hasil pengukuran secara terstruktur sehingga memudahkan proses pengelolaan, pencarian, dan pengambilan data pada tahap analisis[15]. Setiap data yang tersimpan terdiri atas informasi waktu pengukuran (*timestamp*), tinggi muka air, debit, dan volume air. Selanjutnya, data historis tersebut



diekstraksi dari database untuk dilakukan proses *preprocessing* sebelum digunakan dalam pembentukan model prediksi.

4. Tahap Preprocessing

Preprocessing data merupakan langkah untuk pembersihan data sebelum digunakan dalam proses pelatihan model[16]. dataset melalui beberapa tahapan preprocessing, yaitu:

- Mengubah atribut waktu menjadi format datetime.
 - Menjadikan atribut waktu sebagai index dataset.
 - Mengubah seluruh atribut numerik menjadi tipe data float.
 - Mengganti nilai 0 yang dianggap data hilang (missing value) menjadi NaN.
 - Melakukan interpolasi menggunakan metode time interpolation untuk mengisi data yang hilang.
 - Menghapus data yang masih memiliki nilai kosong (drop missing value).
 - Melakukan normalisasi menggunakan metode MinMaxScaler sehingga seluruh data berada pada rentang 0–1 sebelum diproses oleh model. Proses ini dilakukan dengan mengurangi nilai minimum dari setiap fitur, mengatasi perbedaan skala variabel dan memastikan bahwa semua data berada dalam rentang yang seragam[17].
- Pemodelan menggunakan ARIMA digunakan terlebih dahulu untuk memodelkan komponen linear dari data tinggi muka air sungai.
 - Setelah model ARIMA menghasilkan nilai prediksi, residual dihitung sebagai selisih antara data aktual dengan hasil prediksi ARIMA. Residual tersebut merepresentasikan komponen nonlinier yang belum mampu dijelaskan oleh model statistik. Selanjutnya residual dinormalisasi kembali menggunakan MinMaxScaler agar memiliki rentang nilai yang sesuai dengan kebutuhan jaringan LSTM. Data residual kemudian dibentuk menjadi urutan (*sequence*) sepanjang 24 *time step* sebelum digunakan sebagai masukan LSTM.
 - Pelatihan Model LSTM, Setelah proses pelatihan selesai, LSTM menghasilkan prediksi residual, kemudian nilai residual hasil prediksi tersebut dijumlahkan kembali dengan hasil predamalan ARIMA sehingga diperoleh prediksi akhir model Hybrid ARIMA-LSTM. Dengan pendekatan tersebut, ARIMA berperan memodelkan pola linear, sedangkan LSTM berfokus mempelajari hubungan nonlinier yang tersisa sehingga beban pembelajaran model menjadi lebih ringan.

Untuk meminimalkan potensi *overfitting*, penelitian ini menggunakan pembagian data berdasarkan urutan waktu (*time series split*) sebesar 80% untuk pelatihan dan 20% untuk pengujian tanpa melakukan proses *shuffle*. Pendekatan ini dipilih agar hubungan temporal antar data tetap terjaga sehingga kondisi pelatihan lebih merepresentasikan implementasi pada data nyata. Selain itu, jumlah *epoch* dibatasi sebanyak 30 untuk menghindari proses pembelajaran yang berlebihan terhadap data pelatihan[18].

2.2 Long Short-Term Memory (LSTM)

LSTM merupakan salah satu jenis jaringan saraf berulang yang dirancang untuk mempelajari ketergantungan jangka panjang pada data deret waktu, sehingga sangat sesuai untuk pemrosesan data sekuensial. LSTM merupakan pengembangan dari arsitektur Recurrent Neural Network (RNN) yang dilengkapi dengan mekanisme gerbang (*gate*) untuk mengatur aliran informasi di dalam jaringan. Pada arsitektur LSTM, terdapat gerbang input, gerbang forget, dan gerbang output yang berfungsi mengendalikan informasi yang disimpan, diperbarui, atau dibuang pada sel memori. Mekanisme ini memungkinkan jaringan untuk memfilter informasi yang relevan berdasarkan konteks input, sehingga menghasilkan output yang lebih representatif terhadap pola data[4]. Berikut Persamaannya:

$$f_t = \sigma(W_f \cdot [h_{t-1} \ x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1} \ x_t] + b_i) \quad (2)$$

$$\hat{c}_t = \tanh(W_c \cdot [h_{t-1} \ x_t] + b_c) \quad (3)$$

Dimana W_f , W_i , dan W_c masing-masing adalah nilai bobot pada forget gate, input gate, dan cell state. b_f , b_i dan b_c masing-masing adalah bias pada forget gate, input gate, dan cell state. σ adalah fungsi sigmoid[20].

Secara umum, LSTM termasuk dalam keluarga Recurrent Neural Network (RNN), yaitu arsitektur jaringan dengan koneksi berulang yang dirancang untuk memodelkan data yang memiliki ketergantungan urutan dan dimensi waktu. Namun, RNN konvensional memiliki kelemahan utama berupa masalah vanishing gradient, yang menyebabkan kesulitan dalam mempelajari dependensi jangka panjang selama proses pelatihan. Untuk mengatasi permasalahan tersebut, LSTM memperkenalkan sel memori khusus dan mekanisme gerbang pada lapisan tersembunyi, sehingga mampu mempertahankan informasi penting dalam jangka waktu yang lebih panjang. Dengan struktur ini, LSTM umumnya menghasilkan akurasi prediksi yang lebih baik dibandingkan RNN konvensional, yang hanya menggunakan fungsi aktivasi tunggal pada lapisan tersembunyinya[4].

2.3 Autoregressive Integrated Moving Average (ARIMA)

ARIMA merupakan salah satu metode peramalan yang dalam proses analisisnya diawali dengan tahap identifikasi data untuk memastikan sifat stasioneritas sebagai asumsi dasar sebelum dilakukan pengujian lanjutan. Namun, dalam penerapannya, analisis sering mengalami kesulitan dalam melakukan pengujian stasioneritas data. Oleh karena itu,



diperlukan bantuan perangkat lunak statistik yang dapat mempermudah proses analisis tersebut. Metode peramalan runtut waktu yang paling populer dan banyak digunakan untuk data runtut waktu univariat adalah Autoregressive Integrated Moving Average (ARIMA)[5]. Secara umum, metode ARIMA dapat diklasifikasikan menjadi dua jenis, yaitu :

a. ARIMA sederhana

Pemodelan data runtut waktu ini menggunakan metode ARIMA yang tidak mempertimbangkan pengaruh faktor musiman dalam proses pengolahan data[5]. Sehingga model Arima Sederhana dapat ditulis dengan :

$$\text{ARIMA}(p,d,q) \quad (4)$$

Dimana p merupakan orde dari proses Autoregressive (AR) tidak musiman, d adalah ingkat pembedaan (degree of differencing) tidak musiman, dan q adalah orde dari proses Moving Average.

b. ARIMA multiplikatif.

Model ARIMA multiplikatif merupakan pengembangan dari ARIMA yang dirancang untuk menangani data runtut waktu yang memiliki pola musiman dan mengalami pengulangan pada periode tertentu[5]. Sehingga bentuk umum dari model ini dapat ditulis dengan :

$$\text{ARIMA}(p,d,q)(P,D,Q)s \quad (5)$$

Dimana p merupakan orde dari proses Autoregressive (AR) tidak musiman, d adalah tingkat pembedaan (degree of differencing) tidak musiman, dan q adalah orde dari proses Moving Average tidak musiman, selanjutnya P merupakan Orde dari proses autoregressive seasonal(musiman), D adalah Orde pembedaan seasonal (musiman), Q adalah Orde dari moving average seasonal(musiman), dan s adalah Panjang musim (length of seasonality)

2.4 Dataset

Objek penelitian ini adalah tinggi permukaan air sungai menggunakan data *time series* yang dipengaruhi oleh beberapa parameter hidrologi, yaitu tinggi permukaan air sungai, debit aliran sungai, volume air sungai, dan waktu pengukuran. Tinggi permukaan air digunakan sebagai variabel target yang akan diprediksi, sedangkan debit dan volume air digunakan sebagai variabel masukan karena memiliki hubungan hidrologi terhadap perubahan tinggi permukaan air. Adapun waktu pengukuran berfungsi sebagai penanda urutan kronologis data sehingga karakteristik temporal pada data *time series* tetap terjaga selama proses pemodelan. Sumber data dalam penelitian ini terdiri dari terdiri atas data primer dan data sekunder. Data primer diperoleh dari hasil pengukuran langsung menggunakan sensor tinggi permukaan air, debit, dan volume air yang terpasang di Sungai Kebonagung, Kabupaten Sumenep, Madura. Sementara itu, data sekunder berupa data historis yang diperoleh dari Dinas Pekerjaan Umum dan Tata Ruang Bidang Sumber Daya Air, serta berbagai referensi ilmiah yang digunakan sebagai dasar dalam penyusunan penelitian, pengembangan metode, dan analisis hasil penelitian.

Teknik Pengumpulan data dilakukan melalui sistem Internet of Things (IoT) yang memungkinkan proses akuisisi data berlangsung secara otomatis dan berkelanjutan. Sensor tinggi permukaan air, debit, dan volume air melakukan pengukuran secara periodik sesuai interval waktu yang telah ditentukan. Selanjutnya, data hasil pengukuran dibaca oleh mikrokontroler ESP32 yang berfungsi melakukan akuisisi data, memberikan penanda waktu (*timestamp*), serta mempersiapkan data sebelum dikirim ke server. Data kemudian dikirim melalui jaringan internet dan disimpan ke dalam basis data MySQL sebagai data historis berbentuk *time series* yang selanjutnya digunakan sebagai dataset dalam proses *preprocessing*, pelatihan, dan pengujian model prediksi.

Table 1. Karakteristik Dataset

Parameter	Keterangan
Lokasi pengambilan data	Sungai Kebonagung, Kabupaten Sumenep, Madura
Periode pengambilan data	Selama 1 tahun
Jumlah data	±5000 data
Interval sampling	1 jam
Jenis data	Time series multivariat
Variabel	Tinggi permukaan air, debit air, volume air
Target prediksi	Tinggi permukaan air
Format waktu	Timestamp (YYYY-MM-DD HH:MM:SS)

Dataset yang digunakan merupakan data *time series* multivariat yang diperoleh dari sistem monitoring Sungai Kebonagung selama satu tahun dengan interval pengambilan data setiap satu jam. Variabel yang digunakan terdiri atas tinggi muka air sebagai target prediksi, sedangkan debit dan volume air digunakan sebagai variabel pendukung. Pemilihan kedua variabel tersebut didasarkan pada hubungan hidrologi, di mana perubahan debit dan volume air secara langsung memengaruhi perubahan tinggi muka air sungai sehingga diharapkan mampu meningkatkan kemampuan model dalam mengenali pola temporal. Dataset yang telah diperoleh kemudian dibagi menjadi data pelatihan dan data pengujian (testing). Pada penelitian ini digunakan pembagian data sebesar: 80% sebagai data training dan 20% sebagai data testing

Pembagian dilakukan secara berurutan berdasarkan waktu (time series split) sehingga urutan data tetap terjaga dan tidak dilakukan pengacakan (shuffle).



2.5 Evaluasi Model

Performa setiap model dievaluasi menggunakan tiga metrik, yaitu Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). RMSE digunakan untuk mengukur sensitivitas model terhadap kesalahan besar (*large error*), MAE menunjukkan rata-rata kesalahan absolut tanpa memberikan penalti lebih besar terhadap *outlier*, sedangkan MAPE digunakan untuk mengetahui besar kesalahan prediksi dalam bentuk persentase sehingga memudahkan interpretasi performa model.

a. Mean Absolute Error (MAE) : Mengukur rata-rata kesalahan absolut antara nilai prediksi dan nilai aktual [3], [20].

$$MAE = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n} \quad (6)$$

b. Root Mean Squared Error (RMSE) : Mengukur tingkat kesalahan prediksi dengan memberikan penalti lebih besar pada kesalahan besar.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (7)$$

c. Mean Absolute Percentage Error (MAPE).

$$MAPE = \frac{\sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t}}{n} \times 100\% \quad (8)$$

Dimana Y_t menyatakan nilai aktual tinggi muka air sungai, $\hat{Y}_t$ merupakan nilai hasil prediksi model, sedangkan n adalah jumlah keseluruhan data pengujian yang digunakan dalam proses evaluasi.

2.6 Parameter Pelatihan Model

Table 2. Parameter Pelatihan Model

Parameter	Nilai
Window Size	24 data
Sequence Length	24 timestep
Jumlah fitur	3 (Tinggi, Debit, Volume)
Hidden Layer	4 layer
Jumlah neuron Layer 1	64 neuron
Jumlah neuron Layer 2	32 neuron
ARIMA	(2,1,2)
Output Layer	Dense (1 neuron)
Activation Function	Tanh, sigmoid, dan linear activation
Optimizer	Adam
Loss Function	Mean Squared Error (MSE)
Learning Rate	Default Adam (0,001)
Batch Size	16
Epoch	30
Early Stopping	Tidak digunakan
Framework	TensorFlow 2.x (keras)
Waktu Training	26.7 Detik
Waktu Inferensi	0.42 Detik
Spesifikasi CPU	AMD Ryzen 5 3500U, RAM 8 GB
	Python 3.10.11
Konsumsi Memori	1.2 GB

Early stopping tidak diterapkan pada penelitian ini karena selama proses pelatihan hingga *epoch* ke-30 tidak ditemukan indikasi penurunan performa yang signifikan pada data validasi maupun gejala *overfitting* yang ekstrem. Selain itu, jumlah *epoch* yang relatif kecil dipilih untuk menjaga keseimbangan antara akurasi model dan waktu komputasi. Meskipun demikian, penggunaan *early stopping* maupun teknik regularisasi lainnya dapat dipertimbangkan pada penelitian selanjutnya untuk memperoleh model yang lebih optimal dan dapat diterapkan untuk meningkatkan efisiensi waktu dan mengurangi masalah overfitting pada klasifikasi deep learning [22].

3. HASIL DAN PEMBAHASAN

3.1 Hasil Evaluasi

Pengujian dilakukan untuk membandingkan performa tiga pendekatan prediksi, yaitu model LSTM, ARIMA (Debit)-LSTM, dan Hybrid ARIMA-LSTM. Evaluasi dilakukan menggunakan metrik Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Ketiga metrik tersebut dipilih karena mampu



menggambarkan performa model dari sudut pandang yang berbeda, yaitu sensitivitas terhadap kesalahan besar, rata-rata kesalahan absolut, dan tingkat kesalahan dalam bentuk persentase. Hasil evaluasi ketiga model disajikan pada Tabel 3.

Table 3. Hasil Evaluasi

Matrik Evaluasi	LSTM	LSTM+ARIMA	HYBRID
RMSE	128,1488	127,6329951	127,0591
MAE	96,61135	96,33138435	96,81479
MAPE	3,555679	3,55462932	3,59033

Analisis RMSE berdasarkan Tabel 3, model Hybrid ARIMA-LSTM menghasilkan nilai RMSE terendah sebesar 127,06, diikuti oleh ARIMA (Debit)-LSTM sebesar 127,63 dan LSTM sebesar 128,15. Nilai RMSE yang lebih rendah menunjukkan bahwa model Hybrid lebih mampu mengurangi kesalahan prediksi yang berukuran besar (*large error*) dibandingkan dua model lainnya. Hal ini menunjukkan bahwa proses pemisahan komponen linear menggunakan ARIMA sebelum dilakukan pemodelan residual oleh LSTM mampu mengurangi pengaruh fluktuasi ekstrem pada data tinggi muka air sungai.

Analisis MAE berbeda dengan RMSE, nilai MAE terbaik justru diperoleh oleh model ARIMA (Debit)-LSTM sebesar 96,33. Kondisi ini menunjukkan bahwa secara rata-rata prediksi model tersebut memiliki selisih absolut paling kecil terhadap data aktual.

Dengan kata lain, walaupun model Hybrid lebih efektif mengurangi beberapa kesalahan ekstrem, model ARIMA (Debit)-LSTM menghasilkan kesalahan rata-rata yang lebih rendah pada sebagian besar data pengujian. mengukur rata-rata kesalahan absolut. LSTM+ARIMA memiliki MAE paling kecil, sehingga secara rata-rata prediksinya paling dekat dengan nilai aktual.

Analisis MAPE, nilai MAPE seluruh model berada pada kisaran 3,55% hingga 3,59%. Perbedaan yang sangat kecil tersebut menunjukkan bahwa ketiga model memiliki tingkat kesalahan persentase yang hampir sama. Oleh karena itu, peningkatan performa model Hybrid terhadap model lainnya tidak dapat dikatakan sangat signifikan apabila hanya ditinjau dari nilai MAPE. Temuan ini mengindikasikan bahwa integrasi ARIMA dan LSTM lebih berkontribusi terhadap peningkatan stabilitas prediksi dibandingkan peningkatan akurasi secara drastis.

Perbedaan kecenderungan antara nilai RMSE dan MAE menunjukkan bahwa kedua metrik mengevaluasi performa model dari perspektif yang berbeda. RMSE memberikan penalti yang lebih besar terhadap kesalahan berukuran ekstrem karena proses perhitungannya menggunakan kuadrat selisih prediksi. Oleh sebab itu, penurunan RMSE pada model Hybrid mengindikasikan bahwa model mampu mengurangi beberapa kesalahan besar yang muncul ketika terjadi fluktuasi tinggi muka air.

Sebaliknya, MAE menghitung rata-rata seluruh kesalahan absolut tanpa memberikan penalti tambahan terhadap nilai ekstrem sehingga sedikit peningkatan MAE pada model Hybrid menunjukkan bahwa rata-rata kesalahan prediksi pada keseluruhan data masih sedikit lebih besar dibandingkan model ARIMA (Debit)-LSTM. Dengan demikian, model Hybrid dapat dikatakan lebih sensitif dalam memperbaiki kesalahan ekstrem (*outlier*), sedangkan model ARIMA (Debit)-LSTM lebih konsisten menghasilkan kesalahan rata-rata yang rendah.

3.2 Analisis Perbandingan Model

Model LSTM mampu mengikuti pola umum perubahan tinggi air Sungai karena memiliki kemampuan mempelajari hubungan temporal jangka panjang. Namun prediksi yang dihasilkan cenderung lebih halus (*over smoothing*) dibandingkan data aktual sehingga beberapa puncak dan lembah tidak dapat direpresentasikan secara tepat. Kondisi tersebut menunjukkan bahwa LSTM masih mengalami kesulitan dalam mempelajari perubahan tinggi muka air yang berlangsung sangat cepat.


Penambahan hasil prediksi debit dari ARIMA sebagai variabel masukan memberikan informasi tambahan mengenai pola linear dan tren debit sungai. Informasi tersebut membantu LSTM mengenali perubahan kondisi hidrologi secara lebih baik sehingga menghasilkan nilai MAE paling kecil dibandingkan model lainnya. Meskipun demikian, peningkatan performa yang diperoleh relatif kecil karena karakteristik tinggi muka air sungai masih dipengaruhi oleh hubungan nonlinier yang belum sepenuhnya dapat dijelaskan oleh model ARIMA.

Pada model Hybrid, ARIMA terlebih dahulu memodelkan komponen linear dari data tinggi muka air, sedangkan LSTM mempelajari residual yang mengandung hubungan nonlinier. Pendekatan ini menghasilkan proses pembelajaran yang lebih terarah karena LSTM tidak lagi harus mempelajari keseluruhan pola data. Oleh sebab itu, model Hybrid mampu menghasilkan nilai RMSE paling rendah dan menunjukkan performa yang lebih stabil pada beberapa kali proses pelatihan.

Selain akurasi, penelitian ini juga mengevaluasi konsistensi hasil pelatihan model. Model LSTM maupun ARIMA (Debit)-LSTM menunjukkan variasi nilai evaluasi pada setiap proses pelatihan karena proses inisialisasi bobot dilakukan secara acak (*random initialization*).

Sebaliknya, model Hybrid menghasilkan variasi yang lebih kecil karena sebagian besar pola linear telah dimodelkan oleh ARIMA sehingga LSTM hanya mempelajari residual yang memiliki kompleksitas lebih rendah. Kondisi tersebut menyebabkan proses optimasi menjadi lebih stabil dibandingkan model LSTM murni.

3.3 Visualisasi Hasil Prediksi



Gambar 4. Hasil Prediksi

Pada Gambar 4 terlihat bahwa model LSTM mampu mengikuti arah perubahan tinggi muka air, namun amplitudo prediksi lebih kecil dibandingkan data aktual. Fenomena ini menunjukkan adanya efek *smoothing*, yaitu kecenderungan model menghasilkan prediksi yang lebih halus sehingga perubahan ekstrem tidak dapat direpresentasikan secara optimal. Efek tersebut umum dijumpai pada model LSTM ketika data mengandung fluktuasi yang tinggi dalam waktu singkat.

Model ARIMA (Debit)-LSTM memperlihatkan kemampuan yang lebih baik dalam mengikuti perubahan tren jangka menengah karena memperoleh informasi tambahan dari prediksi debit menggunakan ARIMA. Akan tetapi, pada beberapa titik masih terlihat adanya keterlambatan prediksi (*time lag*) ketika terjadi perubahan tinggi muka air secara mendadak.

Model Hybrid menghasilkan pola prediksi yang paling stabil dibandingkan dua model lainnya. Walaupun beberapa puncak ekstrem masih belum dapat direpresentasikan secara sempurna, arah perubahan data aktual dapat diikuti dengan lebih konsisten. Hal tersebut menunjukkan bahwa pemisahan komponen linear dan nonlinier membantu model mengurangi fluktuasi yang tidak diperlukan selama proses pelatihan.

Fenomena *time lag* masih terlihat pada ketiga model, terutama ketika terjadi kenaikan tinggi muka air secara cepat. Keterlambatan ini terjadi karena model melakukan prediksi berdasarkan urutan data historis sepanjang 24 *time step*, sehingga perubahan yang sangat mendadak belum sepenuhnya tercermin pada data masukan. Selain itu, proses pembelajaran LSTM cenderung menghasilkan prediksi yang lebih halus agar kesalahan rata-rata menjadi minimum, sehingga respons terhadap puncak (*peak*) tinggi muka air menjadi sedikit terlambat. Pada model Hybrid, fenomena ini masih muncul meskipun intensitasnya lebih kecil karena sebagian pola linear telah dimodelkan oleh ARIMA. Dalam implementasi sistem peringatan dini banjir, *time lag* dapat menyebabkan informasi mengenai potensi kenaikan muka air diterima lebih lambat. Oleh karena itu, penelitian selanjutnya disarankan menambahkan variabel hidrologi lain seperti curah hujan, intensitas hujan, atau data prakiraan cuaca agar model mampu mengenali perubahan ekstrem lebih cepat.

3.4 Pembahasan

Penelitian mengenai prediksi tinggi muka air sungai telah banyak dilakukan menggunakan berbagai pendekatan. Maulana dan Hakim (2023) menerapkan metode Artificial Neural Network (ANN) untuk mengestimasi tinggi muka air sungai berdasarkan data klimatologi dan memperoleh hasil yang baik dengan nilai MSE sebesar 1,77 dan MAPE sebesar 2,82%. Namun, penelitian tersebut belum memanfaatkan arsitektur Long Short-Term Memory (LSTM) yang dirancang untuk menangani ketergantungan temporal jangka panjang pada data time series, serta belum melakukan perbandingan dengan metode statistik seperti ARIMA [9]. Selanjutnya, Isnandi et al. (2023) menggunakan metode Autoregressive Integrated Moving Average (ARIMA) untuk memprediksi debit aliran sungai berdasarkan data historis dan menunjukkan bahwa ARIMA mampu menangkap pola musiman pada data debit. Akan tetapi, model tersebut masih memiliki keterbatasan dalam memodelkan hubungan nonlinier sehingga akurasi prediksi belum optimal [5].

Agustianto dan Purnamasari (2020) juga menerapkan metode ARIMA pada data rata-rata bulanan ketinggian permukaan Air Sungai Mahakam dengan menambahkan deteksi outlier. Hasil penelitian menunjukkan bahwa pendekatan tersebut mampu menghasilkan model yang cukup baik untuk peramalan tinggi muka air sungai, namun masih menggunakan pendekatan statistik univariat sehingga belum memanfaatkan informasi dari variabel hidrologi lain maupun kemampuan deep learning dalam mempelajari pola nonlinier [12]. Sementara itu, Rais et al. (2022) menggunakan metode LSTM untuk memprediksi kenaikan permukaan air laut berdasarkan data satelit altimetri dan menunjukkan bahwa LSTM mampu mempelajari pola temporal jangka panjang secara efektif. Meskipun demikian, penelitian tersebut dilakukan pada lingkungan laut yang memiliki karakteristik hidrodinamika berbeda dengan sungai dan tidak mengombinasikan LSTM dengan metode statistik untuk memodelkan pola linier [11].



Berbeda dengan penelitian-penelitian tersebut, penelitian ini membandingkan tiga pendekatan, yaitu LSTM, ARIMA (Debit)-LSTM, dan Hybrid ARIMA-LSTM menggunakan dataset time series yang sama berupa data historis hasil pengukuran sensor tinggi muka air, debit, dan volume air Sungai Kebonagung selama satu tahun. Hasil evaluasi menunjukkan bahwa model LSTM menghasilkan nilai RMSE sebesar 128,15, model ARIMA (Debit)-LSTM sebesar 127,63, sedangkan Hybrid ARIMA-LSTM memperoleh nilai RMSE terendah sebesar 127,06. Meskipun peningkatan akurasi yang diperoleh relatif kecil, pendekatan hybrid menunjukkan kemampuan yang lebih baik dalam mengurangi kesalahan prediksi yang ekstrem melalui kombinasi pemodelan komponen linier menggunakan ARIMA dan komponen nonlinier menggunakan LSTM. Dengan demikian, kontribusi utama penelitian ini tidak hanya terletak pada penerapan model hybrid, tetapi juga pada evaluasi dua strategi integrasi ARIMA dan LSTM pada dataset hidrologi yang sama sehingga karakteristik dan performa masing-masing pendekatan dapat dibandingkan secara lebih objektif.

3.5 Keterbatasan Penelitian

Penelitian ini memiliki beberapa keterbatasan. Pertama, dataset hanya berasal dari satu lokasi pengamatan sehingga kemampuan generalisasi model terhadap karakteristik sungai lain belum dapat dipastikan. Kedua, variabel yang digunakan masih terbatas pada tinggi muka air, debit, dan volume tanpa mempertimbangkan faktor hidrologi lain seperti curah hujan, kelembapan udara, maupun kecepatan aliran sungai. Ketiga, konfigurasi hyperparameter masih ditentukan melalui proses *trial and error* sehingga belum menjamin diperolehnya kombinasi parameter yang optimal. Selain itu, penelitian ini belum menerapkan teknik optimasi hyperparameter maupun metode validasi yang lebih komprehensif seperti *walk-forward validation*. Keterbatasan tersebut menjadi peluang pengembangan penelitian pada masa mendatang.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan dan membandingkan tiga pendekatan prediksi tinggi muka air sungai berbasis *time series*, yaitu Long Short-Term Memory (LSTM), ARIMA (Debit)-LSTM, dan Hybrid ARIMA-LSTM menggunakan data historis Sungai Kebonagung. Hasil evaluasi menunjukkan bahwa model Hybrid ARIMA-LSTM menghasilkan nilai RMSE terendah sebesar 127,06, sedangkan model ARIMA (Debit)-LSTM memperoleh nilai MAE dan MAPE terbaik masing-masing sebesar 96,33 dan 3,55%. Perbedaan nilai evaluasi yang relatif kecil menunjukkan bahwa integrasi ARIMA dan LSTM belum memberikan peningkatan akurasi yang signifikan dibandingkan model lainnya, namun mampu menghasilkan prediksi yang lebih stabil dengan mengurangi kesalahan ekstrem melalui pemodelan komponen linear dan nonlinier secara terpisah. Hal ini menunjukkan bahwa pendekatan hybrid lebih berkontribusi dalam meningkatkan konsistensi prediksi daripada menghasilkan peningkatan akurasi yang sangat besar. Kontribusi utama penelitian ini adalah memberikan evaluasi komprehensif terhadap dua strategi integrasi ARIMA dan LSTM menggunakan dataset hidrologi yang sama, sehingga efektivitas masing-masing pendekatan dapat dibandingkan secara objektif. Selain itu, penelitian ini menunjukkan bahwa pemanfaatan variabel hidrologi berupa tinggi muka air, debit, dan volume air mampu mendukung proses pembelajaran model dalam prediksi tinggi muka air sungai berbasis *time series*, sehingga dapat menjadi dasar pengembangan model prediksi untuk sistem peringatan dini banjir. Meskipun demikian, penelitian ini masih memiliki keterbatasan karena menggunakan data dari satu lokasi pengamatan dengan variabel yang terbatas pada tinggi muka air, debit, dan volume air. Oleh karena itu, penelitian selanjutnya disarankan menambahkan variabel hidrologi lain, menerapkan optimasi *hyperparameter* secara otomatis, serta melakukan pengujian pada dataset dari beberapa lokasi sungai agar kemampuan generalisasi model dapat ditingkatkan.

REFERENCES

- [1] J. F. Ruma, M. S. G. Adnan, A. Dewan, and R. M. Rahman, "Particle swarm optimization based LSTM networks for water level forecasting: A case study on Bangladesh river network," *Results Eng.*, vol. 17, no. February, p. 100951, 2023, doi: 10.1016/j.rineng.2023.100951.
- [2] M. Ferdiansyah, S. Ahzan, and D. Pangga, "Pengembangan alat pengukur ketinggian permukaan air pada bendungan berbasis controller sebagai peringatan dini terjadinya banjir," *J. Ilm. IKIP Mataram*, vol. 9, no. 2, 2022, [Online]. Available: <https://ojspanel.undikma.ac.id/index.php/jiim/article/download/7050/4106>
- [3] R. R. Maulana, B. Rochaddi, and Y. J. Wijaya, "Analisis Prediksi Kenaikan Permukaan Laut Menggunakan Data Satelit Altimetri dengan LSTM di Perairan Jepara dan Sekitarnya," *Bul. Oseanografi Mar.*, vol. 14, no. 2, pp. 322–334, 2025, doi: 10.14710/buloma.v14i2.67069.
- [4] A. S. Atmaja, N. F. Muzakki, and Z. D. Oktavian, "Peramalan Tinggi Muka Air Menggunakan Long-Short Term Memory dengan Mekanisme Multi-Head Attention," *Semin. Nas. Off. Stat.*, vol. 2024, no. 1, pp. 625–636, 2024, doi: 10.34123/semnasoffstat.v2024i1.2125.
- [5] A. Isnandi, M. Fauzi, and I. Suprayogi, "Prediksi Debit Aliran Sungai Menggunakan Metode ARIMA (Auto Regressive Integrated Moving Average) Studi Kasus Sungai Tapung Kiri," *Sainstek*, vol. 11, no. 2, pp. 94–101, 2023, [Online]. Available: <https://doi.org/10.35583/js.v11i2.175>.
- [6] N. Sunendar, H. P. Putro, and R. Hesnanda, "Prediksi Penjualan Aerosol Menggunakan Algoritma ARIMA," *INSOLOGI J. Sains dan Teknol.*, vol. 4, no. 1, pp. 113–126, 2025, doi: 10.55123/insologi.v4i1.4868.
- [7] L. Junaedi, N. Damastuti, and A. Widodo, "Penerapan Metode Seasonal ARIMA (SARIMA) untuk Peramalan Penjualan Barang dengan Pola Musiman Tahunan," *JISEM J. Progr. Stud. Inform. Univ. Katolik Widya Mandala Surabaya*, vol. 01, no. 01, pp. 38–48, 2025, doi: <https://doi.org/10.33508/jisem.v1i01.7403>.
- [8] A. F. J. Buamona, R. Gailea, and T. A. Paramitha, "Hubungan Tingkat Debit Air Dan Ketinggian Muka Air Di Sub Das Gumbasa



- Desa Berdikari Kecamatan Palolo Kabupaten Sigi,” *J. FORBIS SAINS*, vol. 4, no. 2, pp. 77–84, 2025, doi: <https://doi.org/10.56338/jfs.v4i2.11488>.
- [9] F. I. Maulana and D. K. Hakim, “Estimasi Tinggi Muka Air Menggunakan Metode Neural Network Pada Wilayah Hilir Pos Brangkal,” *J. Media Pratama*, vol. 17, no. 2, pp. 111–124, 2023.
- [10] M. Subito, T. Blestania, N. Amin, and S. Dewi, “Rancang Bangun Sistem Monitoring Level Permukaan Air Berbasis Internet Of Things (IoT),” *Foristek*, vol. 14, no. 1, 2023, doi: 10.54757/fs.v14i1.247.
- [11] A. Rais, D. A. Lestari, and W. A. Arifin, “Model Prediksi Kenaikan Permukaan Air Laut Menggunakan Data Satelit Altimery Jason-1 dengan pendekatan Algoritma Long-Short Term Memory (Studi Kasus: Teluk Jakarta),” *J. Georaflessia*, vol. 7, no. 2, pp. 165–173, 2022, [Online]. Available: <https://journals.unihaz.ac.id/index.php/georaflessia>
- [12] R. Agustianto and I. Purnamasari, “Analisis Data Ketinggian Permukaan Air Sungai Mahakam Daerah Kutai Kartanegara Tahun 2010-2016 Menggunakan Model Autoregressive Integrated Moving Average (ARIMA) Dengan Efek Outlier (Studi Kasus : Data Rata-rata Ketinggian Tiap Bulan Permukaan Air Sung,” *J. EKSPONENSIAL*, vol. 11, no. 1, pp. 39–46, 2020, [Online]. Available: <https://doi.org/10.30872/eksponensial.v11i1.643>
- [13] Hasbullah and Y. Pramudya, “Pengembangan Sistem Pemantauan Tinggi Gelombang Air Pada Model Tsunami Menggunakan Sensor Ultrasonik Hc-Sr04 Berbantuan Arduino,” *J. Syntax IDEA*, vol. 6, no. 2, 2024, doi: <https://doi.org/10.46799/syntax-idea.v6i2.2849>.
- [14] A. Aziz, “Implementasi Mikrokontroler ESP32 Dan Sensor Kualitas Air Dalam Sistem Monitoring Lingkungan Berbasis Internet of Things,” *J. Manaj. Sist. Inf.*, vol. 5, no. 1, pp. 1–13, 2026, doi: 10.59431/jmasif.v5i1.716.
- [15] T. Hariono and M. Ulum, “Perancangan Alat Pembayaran Santri Berbasis Esp32 Pada Koperasi Pondok Pesantren Al-Ghozali,” *J. Sains Student Res.*, vol. 3, no. 6, pp. 1112–1124, 2025, doi: <https://doi.org/10.61722/jssr.v3i6.7070>.
- [16] I. N. Simbolon and W. A. Manik, “Prediksi Kualitas Air Sungai Di Jakarta,” *JITET (Jurnal Inform. dan Tek. Elektro Ter.*, vol. 12, no. 2, 2024, [Online]. Available: <http://dx.doi.org/10.23960/jitet.v12i2.4191>
- [17] M. R. Syailendra *et al.*, “OPTIMALISASI REGRESI LINEAR BERGANDA NORMALISASI,” *J. SIMETRIS*, vol. 17, no. 1, pp. 205–218, 2026, doi: <https://doi.org/10.24176/simet.v17i1.16777>.
- [18] S. Khodijah and C. A. Rizki, “Analisis Kinerja Algoritma Deep Learning pada Pengolahan Data Kompleks,” *J. Electr. Eng. Res.*, vol. 1, no. 3, pp. 91–97, 2026, doi: <https://doi.org/10.64803/joeer.v1i3.20>.
- [19] M. Judianto, T. Informatika, U. Tarumanagara, J. Letjen, S. P. No, and J. Indonesia, “Peramalan Harga Saham Dengan Metode Long Short Term Memory (LSTM),” *J. Ilmu Komput. dan Sist. Inf.*, vol. 12, no. 1, pp. 1–5, 2024, [Online]. Available: <https://doi.org/10.24912/jiksi.v12i1.28194>
- [20] D. Candra, R. Novitasari, P. K. Intan, and G. G. Wisnawa, “Penerapan Metode Principal Component Analysis (PCA) dan Long Short-Term Memory (LSTM) dalam Memprediksi Prediksi Curah Hujan Harian,” *Build. Informatics, Technol. Sci.*, vol. 5, no. 1, pp. 1–11, 2023, doi: 10.47065/bits.v5i1.3114.
- [21] I. Berbasis, M. Learning, and F. Lazuardi, “Pengaruh Volume Air Terhadap Prediksi Penggunaan Air Bersih pada Sistem,” *SNIV Semin. Nas. Inov. VOKASI*, vol. 4, no. 1, pp. 62–70, 2025, [Online]. Available: <https://prosiding.pnj.Ac.Id/Index.Php/Sniv/Article/View/3802>
- [22] I. Moeslem *Et Al.*, “Deep Learning Dengan Teknik Early Stopping Untuk Mendeteksi Deep Learning With Early Stopping Technique For Malware Detection On Iot Devices,” *J. Teknol. Inf. dan Ilmu Komput. (JTIK)*, vol. 12, no. 1, pp. 21–30, 2025, doi: 10.25126/jtiik.2025128267.