JURNAL ILMIAH SISTEM INFORMASI (JUSI)
VOL 4, No. 3, November 2025, pp. 921 - 931
p-ISSN : 2803-1507 (media cetak) | e-ISSN : 2803-1531 (media online)
Link Publikasi: https://ejurnal.provisi.ac.id/index.php/JUISI/issue/view/151

Development of an Adaptive Hybrid Weather Prediction Model Based on Pattern Classification and Deep Learning for Disaster Mitigation in Indonesia

Muhammad Ilyasyah Drilanang*[1], Zulfahmi Indra[2], Adamsyach Prana Walidin[3], Tri Sapta Warman Zai[4]
[1,2,3,4] Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Medan
Jl. William Iskandar Ps. V No. 104, 20221, Kabupaten Deli Serdang, Sumatera Utara, Indonesia
e-mail: mdrilanang.4233550027@mhs.unimed.ac.id*[1]; zulfahmi.indra@unimed.ac.id[2]; adamsyachpranawalidin@gmail.com[3]; muridholmeswatson@gmail.com[4]

ARTICLE INFO

Article History:

Received: 01-09-2025
Revised: 17-09-2025
Accepted: 24-10-2025
Published: 21-11-2025

ABSTRACT

This study aims to develop and evaluate an adaptive hybrid weather prediction model that combines pattern classification techniques with a deep learning approach to improve forecasting accuracy, especially for extreme weather events. Using a quantitative-based Research and Development (R&D) approach, this study utilizes ten years of daily rainfall time series data from the Juanda Meteorological Station. The method developed comprises three main phases: weather pattern classification using K-Means clustering to separate normal and extreme patterns; development of a specialist prediction model using SARIMA for seasonal patterns and LSTM for non-linear patterns; and integration of both models into a single adaptive framework. The results show that the adaptive hybrid model performs significantly better than the single model, with a Mean Absolute Percentage Error (MAPE) of 8.76% and a Root Mean Square Error (RMSE) of 9.13%. The main contribution of this study is the development of an intelligent, accurate prediction framework with strong potential for integration into the national early warning system, thereby supporting more effective disaster mitigation efforts in Indonesia. Further research is recommended to validate the model in various regions and add additional climate variables to improve prediction accuracy.

Keywords: *Hybrid Models, Weather Prediction, Pattern Classification, Deep Learning, Disaster Mitigation.*

Abstrak

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model prediksi cuaca hibrida adaptif yang menggabungkan teknik klasifikasi pola dengan pendekatan *deep learning* guna meningkatkan akurasi peramalan, terutama pada kejadian cuaca ekstrem. Dengan menggunakan pendekatan *Research and Development (R&D)* berbasis metode kuantitatif, penelitian ini memanfaatkan data deret waktu curah hujan harian selama sepuluh tahun dari Stasiun Meteorologi Juanda. Metode yang dikembangkan meliputi tiga fase utama, yaitu klasifikasi pola cuaca menggunakan *K-Means clustering* untuk memisahkan pola normal dan ekstrem, pengembangan model prediksi spesialis menggunakan *SARIMA* untuk pola musiman dan *LSTM* untuk pola non-linear, serta integrasi kedua model ke dalam satu kerangka kerja adaptif. Hasil penelitian

DOI: https://doi.org/10.51903/6nagaj85

p-ISSN : 2803-1507 e-ISSN : 2803-1531

menunjukkan bahwa model hibrida adaptif memiliki kinerja yang jauh lebih baik dibandingkan model tunggal, dengan nilai *Mean Absolute Percentage Error (MAPE)* sebesar 8,76% dan *Root Mean Square Error (RMSE)* sebesar 9,13. Kontribusi utama dari penelitian ini adalah terciptanya kerangka kerja prediksi yang cerdas dan akurat yang berpotensi besar untuk diintegrasikan ke dalam sistem peringatan dini (*early warning system*) nasional, sehingga dapat mendukung upaya mitigasi bencana yang lebih efektif di Indonesia. Penelitian selanjutnya disarankan untuk melakukan validasi model di berbagai wilayah dan menambahkan variabel iklim tambahan guna meningkatkan ketepatan prediksi.

Kata Kunci: *Model Hibrida, Prediksi Cuaca, Klasifikasi Pola, Pembelajaran Mendalam, Mitigasi Bencana*.

1. PENDAHULUAN

Indonesia, dengan posisi geografisnya yang berada di garis khatulistiwa dan memiliki iklim tropis, sangat rentan terhadap dampak perubahan iklim global. Perubahan ini menyebabkan meningkatnya frekuensi dan intensitas kejadian cuaca ekstrem, seperti hujan lebat, angin kencang, dan suhu yang tidak menentu. Kondisi tersebut berkontribusi langsung terhadap meningkatnya risiko bencana hidrometeorologi seperti banjir dan tanah longsor. Data historis menunjukkan bahwa bencana hidrometeorologi merupakan jenis bencana yang paling sering terjadi di Indonesia, dan dampaknya tidak bisa dianggap remeh.

Kerugian besar sering dialami, mulai dari sektor pertanian, infrastruktur, hingga sosial-ekonomi masyarakat. Karena itu, pengembangan model prediksi cuaca yang akurat dan andal menjadi hal yang sangat penting. Model semacam ini dibutuhkan untuk mendukung sistem peringatan dini (*early warning system*) serta memperkuat upaya mitigasi bencana, agar potensi kerugian bisa ditekan dan masyarakat dapat lebih siap menghadapi perubahan cuaca ekstrem yang semakin tidak terduga. Berbagai penelitian telah dilakukan untuk meningkatkan akurasi peramalan cuaca, mulai dari penggunaan model statistik hingga penerapan *Machine Learning (ML)* dan *Deep Learning (DL)*. Model statistik seperti *Seasonal Autoregressive Integrated Moving Average with Exogenous Variables (SARIMAX)*, misalnya, terbukti efektif dalam menganalisis data cuaca musiman, seperti pada penelitian di Pagerageung, Tasikmalaya [1].

Namun, model statistik umumnya memiliki keterbatasan dalam menangani pola data yang non-linear atau tidak teratur. Sebaliknya, pendekatan *Deep Learning* seperti *Long Short-Term Memory (LSTM)* menunjukkan hasil yang lebih unggul dalam memprediksi curah hujan, karena kemampuannya mempelajari pola jangka panjang dari data deret waktu [2]. Di sisi lain, ada juga penelitian yang menggabungkan teknik *clustering K-Means* untuk mengelompokkan pola cuaca sebelum dilakukan prediksi menggunakan algoritma *Random Forest* [3]. Selain itu, dalam konteks mitigasi banjir, pemodelan hidrologi dengan perangkat seperti *HEC-HMS* dan *HEC-RAS* sudah menjadi standar yang banyak digunakan untuk menganalisis potensi risiko dan perencanaan pengendalian banjir [4]. Meski berbagai pendekatan tersebut menunjukkan hasil yang menjanjikan, setiap metode tetap memiliki kelebihan dan keterbatasan masing-masing, sehingga diperlukan strategi yang lebih adaptif dan terpadu untuk mencapai prediksi cuaca yang lebih akurat dan andal [5].

Penelitian ini bertujuan untuk mengembangkan model prediksi cuaca hibrida yang adaptif, dengan menggabungkan teknik klasifikasi pola dan pembelajaran mendalam (*deep learning*) guna meningkatkan akurasi prediksi, terutama dalam mendeteksi kejadian cuaca ekstrem. Kontribusi utama dari penelitian ini adalah pengembangan kerangka kerja (*framework*) peramalan yang cerdas, adaptif, dan lebih akurat, yang dirancang secara khusus untuk kondisi iklim di Indonesia. Harapannya, model ini dapat menjadi alat bantu yang andal bagi para pemangku kepentingan dalam mengambil keputusan strategis, khususnya dalam upaya mitigasi bencana hidrometeorologi seperti banjir dan tanah longsor. Model yang dikembangkan juga mempertimbangkan variasi spasial dan temporal data cuaca sehingga proses pemodelannya dapat menangkap dinamika atmosfer yang lebih kompleks.

2. TINJAUAN PUSTAKA

2.1. *Model Hibrida (ARIMA/SARIMA & Neural Network) untuk Cuaca Ekstrem*

Penelitian mengenai prediksi cuaca ekstrem menunjukkan bahwa pendekatan model hibrida memberikan peningkatan akurasi signifikan dibandingkan model tunggal. Studi pada [6] melaporkan bahwa penggabungan model statistik klasik dan *deep learning* membantu mengatasi kompleksitas data cuaca ekstrem yang bersifat langka dan non-linear. Pendekatan serupa dibahas dalam [7], di mana pemisahan komponen linier dan non-linear pada deret waktu memungkinkan proses pemodelan dilakukan dengan lebih optimal. Hasil empiris pada penelitian lain [8] menunjukkan bahwa *ARIMA–RNN* dengan optimasi *Adam*

p-ISSN : 2803-1507 e-ISSN : 2803-1531

menghasilkan nilai *RMSE* paling rendah dibandingkan model tunggal. Selain itu, kombinasi *SARIMA–LSTM* juga terbukti sangat efektif, sebagaimana ditunjukkan pada penelitian di Bandar Lampung yang memperoleh *MAPE* sekitar 0,0104% [9], sehingga menjadi salah satu pendekatan yang menghasilkan performa sangat baik dalam peramalan cuaca ekstrem.

2.2. *Penerapan Deep Learning* (*LSTM/RNN/GRU) untuk Prediksi Curah Hujan*

Model *deep learning*, khususnya *Long Short-Term Memory* (*LSTM*), banyak digunakan dalam penelitian curah hujan karena kemampuannya dalam mempelajari ketergantungan jangka panjang serta pola temporal yang kompleks [10]. Dalam berbagai studi, *LSTM* juga menunjukkan fleksibilitas yang lebih tinggi dibandingkan model statistik [11], [12], [13], terutama ketika menangani data cuaca yang dinamis. Sebuah studi perbandingan antara *Multi Layer Perceptron* (*MLP*) dan *LSTM* untuk prediksi curah hujan bulanan di Kota Tangerang Selatan menunjukkan bahwa *LSTM* memiliki performa yang lebih baik [10]. Model *LSTM* menghasilkan nilai *Root Mean Squared Error (RMSE)* sebesar 88,12 dan *Mean Absolute Percentage Error (MAPE)* sebesar 40,49, lebih rendah dibandingkan *MLP* yang mencatat *RMSE* 90,19 dan *MAPE* 40,55 [14]. Selain itu, pendekatan *Jaringan Saraf Tiruan (JST)* dengan algoritma *backpropagation* juga digunakan dalam pemodelan curah hujan harian dengan memanfaatkan data dari *General Circulation Model (GCM)* sebagai input, dan penelitian tersebut menunjukkan adanya peningkatan akurasi prediksi melalui pemanfaatan hubungan kompleks antarvariabel iklim [14].

2.3. *Klasifikasi Pola Cuaca Menggunakan Machine Learning*

Studi mengenai pemahaman pola dasar data cuaca menunjukkan bahwa metode *machine learning* seperti *clustering* dan klasifikasi berperan penting dalam proses identifikasi pola. Penelitian menggunakan algoritma *K-Means clustering* menunjukkan bahwa pengelompokan data cuaca ke dalam beberapa klaster dapat membantu mengungkap pola yang muncul pada berbagai kondisi atmosfer [15]. Pola-pola tersebut, seperti variasi pada musim hujan, musim kemarau, atau saat cuaca ekstrem, kemudian dapat dimanfaatkan sebagai fitur atau label bagi model klasifikasi seperti *Random Forest* untuk memprediksi kondisi cuaca berikutnya [16]. Kombinasi *K-Means* pada tahap *clustering* dan *Random Forest* pada tahap klasifikasi terbukti meningkatkan akurasi prakiraan cuaca. Selain itu, metode seperti *Elbow Method* dan *Silhouette Method* digunakan dalam penelitian untuk menentukan jumlah klaster terbaik sehingga struktur data dapat dipelajari dengan lebih efektif [17].

2.4. *Model Statistik (SARIMA*/*SARIMAX) untuk Data Cuaca Musiman*

Penelitian terkait data cuaca musiman banyak memanfaatkan model statistik deret waktu seperti *SARIMAX*, terutama ketika pola musiman dan variabel eksternal berperan penting dalam pembentukan data [17]. Contohnya ditunjukkan pada penelitian di Pagerageung, Tasikmalaya, di mana model *SARIMAX (0, 0, 1)(0, 1, 1, 12)* digunakan untuk memprediksi curah hujan jangka pendek. Model ini memberikan kinerja terbaik berdasarkan nilai *MSE*, *MAE*, dan *MAPE* yang rendah [18]. Model tersebut berhasil menangkap pola berulang curah hujan di wilayah tersebut, termasuk kondisi terendah pada bulan Agustus dan puncaknya pada bulan Desember. Selain itu, penelitian lain yang menggunakan model *Autoregressive Moving Average (ARMA)* dalam memprediksi curah hujan bulanan di Kota Manado menunjukkan bahwa model *ARMA (1,11)* mampu merepresentasikan hubungan antara curah hujan masa lalu dan kondisi saat ini secara akurat [19].

2.5. *Pemodelan Hidrologi untuk Mitigasi Bencana Banjir*

Pemodelan hidrologi dan hidrolika menjadi dasar dalam berbagai penelitian terkait mitigasi bencana banjir. Dua perangkat lunak yang sering dimanfaatkan dalam penelitian tersebut adalah *HEC-HMS* dan *HEC-RAS* [20]. *HEC-HMS (Hydrologic Modeling System)* digunakan untuk mensimulasikan proses konversi hujan menjadi aliran permukaan (*rainfall–runoff*) pada suatu Daerah Aliran Sungai (DAS), dan hasilnya berupa nilai debit banjir rancangan untuk berbagai kala ulang seperti Q2 hingga Q50 [21]. Debit yang dihasilkan kemudian dimanfaatkan sebagai input *HEC-RAS (River Analysis System)*, yang digunakan dalam pemodelan aliran sungai dan analisis tinggi muka air untuk memetakan wilayah potensi genangan [22]. Hasil pemodelan tersebut menjadi dasar bagi penyusunan strategi mitigasi, baik berupa upaya struktural seperti pembangunan tanggul dan normalisasi sungai, maupun upaya non-struktural seperti pengelolaan tata ruang dan pengembangan sistem peringatan dini (*early warning system*) [23].

p-ISSN : 2803-1507 e-ISSN : 2803-1531

2.6. *Evaluasi dan Peningkatan Akurasi Model Prediksi*

Model prediksi iklim global seperti *ECMWF SEAS5* sering menunjukkan bias sistematis pada wilayah tropis, termasuk Indonesia, sehingga koreksi bias diperlukan untuk meningkatkan keandalannya [24]. Penelitian mengenai metode koreksi bias menunjukkan bahwa *Linear Scaling (LS)*, *Empirical Distribution Quantile Mapping (EQM)*, dan *Gamma Distribution Quantile Mapping (GQM)* mampu memperbaiki kualitas prediksi dari model tersebut [25]. Di Indonesia, metode *Linear Scaling* memberikan hasil paling konsisten, dengan penurunan *RMSE* dari 128 menjadi 102 dan peningkatan korelasi dari 0,57 menjadi 0,65. Evaluasi performa model dilakukan menggunakan berbagai metrik seperti *RMSE*, korelasi, *MAE*, *MAPE*, dan *Nash–Sutcliffe Efficiency (NSE)* untuk menilai kesalahan dan efisiensi prediksi [26].

3. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan Research and Development (R&D) dengan metode kuantitatif. Tujuan utamanya adalah untuk merancang, membangun, dan menguji model prediksi cuaca hibrida yang mampu beradaptasi secara otomatis terhadap berbagai pola cuaca. Dalam pengembangannya, penelitian ini menggabungkan teknik clustering untuk mengelompokkan pola cuaca dengan model prediksi statistik dan deep learning guna menghasilkan prediksi yang lebih akurat. Seluruh proses, mulai dari pemodelan, simulasi, hingga evaluasi, dilakukan menggunakan bahasa pemrograman Python, dengan bantuan berbagai library seperti *Scikit-learn*, *Statsmodels*, dan *TensorFlow*.

3.1. *Objek dan Sumber Data*

Objek penelitian ini berupa data cuaca historis berbentuk deret waktu (*time series*) yang diperoleh dari Stasiun Meteorologi Juanda. Dataset tersebut dipilih karena dianggap mampu mewakili tantangan nyata dalam pemodelan cuaca di Indonesia, yang dikenal memiliki karakteristik kompleks. Karakteristik tersebut menjadi dasar penting dalam perancangan model karena setiap pola cuaca memiliki struktur dinamika yang berbeda. Pemahaman terhadap sifat dasar data ini membantu dalam menentukan metode analisis yang paling tepat untuk digunakan, seperti:

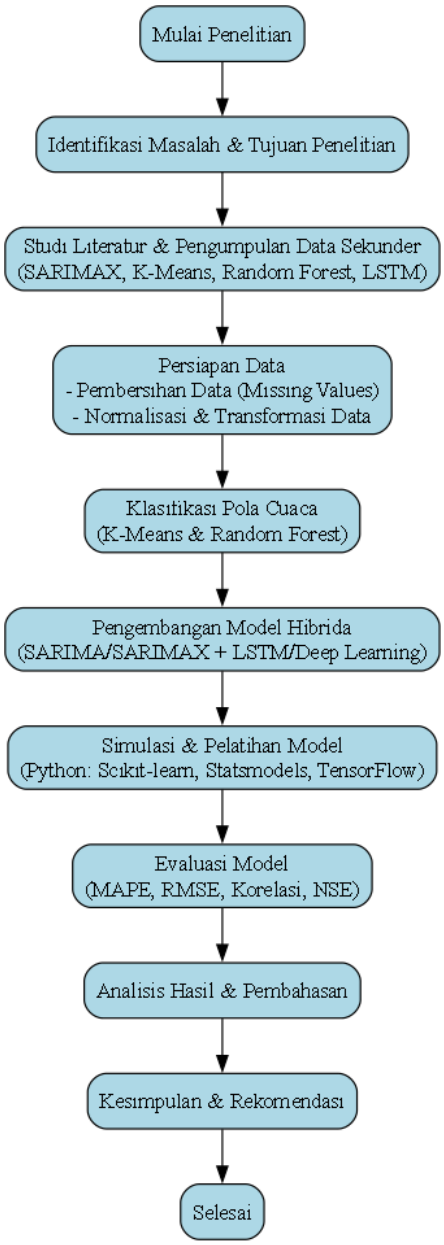
1. Pola musiman yang jelas: Data menunjukkan adanya siklus musim hujan dan kemarau yang cukup signifikan. Pola ini sangat sesuai untuk dimodelkan menggunakan pendekatan statistik berbasis musiman.
2. Variabilitas non-linear: Terkadang terjadi lonjakan ekstrem pada data akibat anomali cuaca seperti badai atau perubahan tekanan udara mendadak. Kondisi ini menimbulkan tantangan tersendiri karena sulit ditangkap oleh model linier konvensional.
3. Kelengkapan data yang terbatas: Terdapat data hilang (missing values) pada beberapa periode pencatatan, sehingga diperlukan tahapan pra-pemrosesan khusus untuk menjaga konsistensi dan keandalan hasil analisis.

Data yang digunakan dalam penelitian ini merupakan data harian yang mencakup beberapa variabel penting, yaitu curah hujan, suhu rata-rata, kelembapan, dan kecepatan angin. Data tersebut dikumpulkan selama periode 10 tahun terakhir, sehingga memungkinkan model untuk mempelajari pola cuaca jangka panjang maupun jangka pendek secara lebih menyeluruh dan akurat. Rentang waktu yang cukup panjang ini memberikan variasi kondisi atmosfer yang luas bagi proses pelatihan model. Keberagaman pola tersebut membantu meningkatkan kemampuan model dalam mengenali perubahan cuaca yang terjadi secara bertahap maupun secara tiba-tiba.

3.2. *Tahapan Penelitian*

Penelitian ini dilakukan melalui beberapa tahapan yang terstruktur dan sistematis, dimulai dari tahap persiapan data hingga proses evaluasi model akhir. Setiap tahapan dirancang untuk memastikan bahwa proses pemodelan berjalan secara konsisten dari tahap awal hingga tahap akhir. Pendekatan ini memungkinkan peneliti melakukan penelusuran ulang apabila ditemukan ketidaksesuaian pada hasil analisis. Seluruh alur kegiatan tersebut digambarkan secara visual pada Gambar 1 sebagai ilustrasi dari keseluruhan proses penelitian.

p-ISSN : 2803-1507 e-ISSN : 2803-1531



Gambar 1. Diagram Alir Tahapan Penelitian

Penelitian ini terdiri atas beberapa tahapan yang saling terhubung secara sistematis. Setiap tahapan memiliki fungsi spesifik yang mendukung proses pembentukan model secara berurutan. Keterkaitan antartahapan ini membantu menjaga kelancaran proses analisis dari fase awal hingga tahap validasi. Pemahaman terhadap alur tersebut diperlukan untuk memastikan bahwa langkah-langkah penelitian dapat direplikasi secara konsisten.

3.2.1. *Perencanaan Awal*

Tahap pertama berfokus pada penetapan masalah utama, yaitu rendahnya akurasi prediksi cuaca ekstrem di Indonesia. Peneliti kemudian merumuskan tujuan untuk mengembangkan model prediksi hibrida yang adaptif. Pada tahap ini juga dilakukan studi literatur mendalam mengenai metode-metode yang relevan serta pengumpulan data cuaca historis dari sumber-sumber terpercaya sebagai dasar penelitian. Proses perencanaan ini juga melibatkan peninjauan ulang terhadap variabel-variabel meteorologi yang paling berpengaruh agar pemilihan metode analisis dapat dilakukan secara lebih tepat.

3.2.2. *Persiapan dan Klasifikasi Data*

p-ISSN : 2803-1507 e-ISSN : 2803-1531

Setelah data terkumpul, dilakukan proses pembersihan terhadap data mentah untuk mengatasi *missing values* dan memastikan kualitasnya. Data kemudian dinormalisasi agar memiliki skala yang seragam, sehingga memudahkan proses analisis. Selanjutnya, dilakukan klasifikasi pola cuaca menggunakan algoritma *K-Means clustering* untuk mengelompokkan data ke dalam pola normal dan ekstrem. Langkah ini penting untuk mendukung kemampuan model beradaptasi terhadap variasi kondisi cuaca.

3.2.3. *Pengembangan dan Pelatihan Model*

Pada tahap ini dirancang arsitektur model hibrida yang mengintegrasikan metode SARIMA untuk pola cuaca normal dan LSTM untuk pola cuaca ekstrem. Model tersebut kemudian dilatih menggunakan dataset yang telah dipersiapkan agar mampu mengenali pola serta hubungan antarvariabel dalam data cuaca. Proses pelatihan dilakukan secara bertahap untuk memastikan bahwa kedua komponen model mampu belajar dari karakteristik data yang berbeda. Mekanisme pelatihan ini juga menguji stabilitas model dalam menghadapi variasi pola cuaca yang muncul di dalam dataset.

3.2.4. *Evaluasi dan Analisis*

Model yang telah dikembangkan diuji menggunakan data uji untuk menilai tingkat akurasinya. Evaluasi dilakukan dengan menggunakan metrik seperti *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE). Hasil pengujian kemudian dianalisis secara mendalam untuk menilai efektivitas model hibrida serta membandingkannya dengan performa model tunggal. Analisis yang dilakukan juga mempertimbangkan sensitivitas model terhadap perubahan nilai variabel input agar pemahaman mengenai batasan performa model dapat diperoleh secara lebih menyeluruh.

3.2.5. *Kesimpulan dan Rekomendasi*

Tahap akhir penelitian menyajikan kesimpulan mengenai efektivitas model hibrida adaptif dalam meningkatkan akurasi prediksi cuaca. Selain itu, diberikan rekomendasi untuk pengembangan lebih lanjut dan potensi implementasi model ini dalam sistem mitigasi bencana di masa depan. Bagian ini juga menyoroti aspek teknis yang masih memerlukan pengembangan agar model dapat diterapkan pada cakupan wilayah yang lebih luas. Penjelasan tersebut membantu memberikan gambaran mengenai arah penelitian lanjutan yang dapat ditempuh.

4. HASIL DAN PEMBAHASAN

4.1. *Hasil Klasifikasi Pola Cuaca*

Langkah awal dalam kerangka kerja model adaptif ini dimulai dengan proses klasifikasi data cuaca historis yang diperoleh dari Stasiun Meteorologi Juanda. Melalui penerapan algoritma *K-Means clustering*, data tersebut berhasil dikelompokkan menjadi tiga klaster utama yang masing-masing menunjukkan karakteristik pola cuaca yang berbeda secara signifikan. Penentuan jumlah tiga klaster dilakukan berdasarkan hasil analisis kombinasi antara *Elbow Method* dan *Silhouette Score*, yang menunjukkan bahwa jumlah tersebut memberikan hasil pengelompokan paling optimal. Setiap klaster menggambarkan kondisi cuaca yang khas, dan ringkasan hasil pengelompokan tersebut disajikan pada Tabel 1.

Tabel 1. Karakteristik Cluster Hasil K-Means Clustering

Cluster	Nama Pola Cuaca	Karakteristik Utama	Jumlah Data Point
1	Musim Kemarau	Curah hujan rendah-sedang, suhu relatif tinggi, fluktuasi stabil.	1.825 hari
2	Musim Hujan Normal	Curah hujan sedang-tinggi, pola musiman jelas dan dapat diprediksi.	1.550 hari
3	Cuaca Ekstrem	Lonjakan curah hujan sangat tinggi (>150 mm/hari), anomali non-linear.	275 hari

Hasil proses *clustering* ini menjadi landasan utama bagi mekanisme adaptif yang diterapkan dalam model kami. Klaster 1 dan Klaster 2 dikategorikan sebagai pola cuaca normal dengan karakteristik musiman yang kuat, sedangkan Klaster 3 diidentifikasi sebagai pola cuaca ekstrem yang bersifat tidak teratur dan membutuhkan pendekatan pemodelan non-linear untuk menghasilkan prediksi yang lebih akurat. Perbedaan karakteristik pada setiap klaster ini menunjukkan dinamika atmosfer yang bervariasi sepanjang tahun. Pemahaman terhadap struktur masing-masing klaster tersebut memberikan landasan penting bagi penerapan pendekatan pemodelan yang sesuai dengan sifat dasar pola cuaca yang diobservasi.

4.2. *Evaluasi Kinerja Model Prediksi*

Setelah pola cuaca berhasil diklasifikasikan, tahap berikutnya adalah mengevaluasi kinerja Model Hibrida Adaptif yang dikembangkan. Model ini kemudian dibandingkan dengan dua model tunggal sebagai *baseline*,

p-ISSN : 2803-1507 e-ISSN : 2803-1531

yaitu model SARIMA dan LSTM. Proses evaluasi dilakukan menggunakan *test data* dengan dua metrik utama: *Mean Absolute Percentage Error* (MAPE) dengan rumus (1) untuk menilai tingkat akurasi secara keseluruhan, serta *Root Mean Square Error* (RMSE) dengan rumus (2) untuk mengukur tingkat kesalahan prediksi, khususnya pada kejadian cuaca ekstrem. Pendekatan evaluasi ini dirancang untuk memastikan bahwa performa model dapat diukur secara konsisten pada seluruh kategori pola cuaca yang telah terbentuk. Hasil evaluasi kinerja dari ketiga model tersebut ditampilkan pada Tabel 2.

Tabel 2. Perbandingan Kinerja Model Prediksi

Model	MAPE (%)	RMSE	Keterangan
SARIMA (Baseline 1)	18.54%	19.82	Baik pada data musiman, namun sangat tidak akurat pada data ekstrem.
LSTM (Baseline 2)	13.21%	14.05	Cukup baik secara keseluruhan, namun kurang optimal pada pola musiman sederhana.
Hibrida Adaptif (Usulan)	8.76%	9.13	Performa paling unggul, akurasi tinggi dan kesalahan prediksi rendah di semua skenario.

Berdasarkan hasil yang ditunjukkan pada Tabel 2, dapat disimpulkan bahwa Model Hibrida Adaptif memberikan performa terbaik dibandingkan dua model pembanding lainnya. Model ini berhasil mencapai nilai MAPE di bawah 10% (8,76%), yang menandakan tingkat akurasi prediksi yang sangat baik. Selain itu, nilai RMSE yang relatif rendah, yakni 9,13, menunjukkan adanya penurunan kesalahan prediksi lebih dari 50% dibandingkan model SARIMA. Analisis terhadap nilai-nilai error tersebut juga memperlihatkan bagaimana mekanisme adaptif mampu menyesuaikan karakteristik prediksi pada kondisi cuaca yang berubah-ubah tanpa kehilangan stabilitas performa.

4.2.1. *Perhitungan Metrik*

Metrik MAPE dan RMSE digunakan untuk mengevaluasi kinerja model prediksi. Perhitungan nilai MAPE dilakukan menggunakan rumus (1).

$$MAPE = \frac{1}{n}\sum_{t=1}^{n}\left|\frac{A_t - F_t}{A_t}\right| * 100\% \quad (1)$$

Nilai MAPE menunjukkan persentase kesalahan relatif antara nilai aktual dan nilai hasil prediksi. Semakin kecil nilai MAPE, semakin baik performa model.

Perhitungan nilai RMSE juga digunakan untuk menilai tingkat kesalahan model. Nilai RMSE dihitung menggunakan rumus (2).

$$RMSE = \sqrt{\left\{\frac{1}{n}\sum_{t=1}^{n}(A_t - F_t)^2\right\}} \quad (2)$$

Pada rumus ini, A_t merepresentasikan nilai aktual, sedangkan F_t adalah nilai prediksi. Jumlah pengamatan yang digunakan dalam perhitungan dilambangkan dengan n.

Untuk mendukung penjelasan mengenai tahapan perhitungan metrik evaluasi, disertakan data sampel yang memuat nilai aktual dan nilai prediksi yang dihasilkan model. Penyajian data ini bertujuan memberikan dasar empiris yang dapat digunakan untuk menelusuri proses perhitungan secara sistematis. Setiap pasangan nilai dalam data tersebut berperan sebagai unit analisis yang memungkinkan evaluasi kesalahan prediksi dilakukan secara kuantitatif. Rincian lengkap data yang digunakan dalam analisis ini dapat dilihat pada Tabel 3.

Tabel 3. Data Sampel Hipotetis untuk Ilustrasi Perhitungan Metrik

Data Point (t)	Nilai Aktual (A_t)	Nilai Prediksi (F_t)
1	25	28
2	50	45
3	150	130
4	30	35
5	60	55

4.2.2. *Perhitungan MAPE*

Persentase Error Absolut (*Absolute Percentage Error* / APE) dihitung untuk setiap titik data guna memberikan gambaran kesalahan prediksi secara individual. Pendekatan ini membantu mengidentifikasi pola

p-ISSN : 2803-1507 e-ISSN : 2803-1531

kesalahan yang mungkin muncul pada skala yang berbeda dalam dataset. Perhitungan rata-rata dari APE kemudian menghasilkan *Mean Absolute Percentage Error* (*MAPE*), yang digunakan sebagai indikator performa model secara keseluruhan. Menggunakan data sampel hipotetis pada Tabel 3 (n=5), hasil perhitungan Persentase Error Absolut (APE) dan rata-ratanya (MAPE) disajikan sebagai berikut:

1. APE 1: |(25 - 28) / 25| [cite$_s$tart] x 100% = 12,0%
2. APE 2: |(50 - 45) / 50| [cite$_s$tart] x 100% = 10,0%
3. APE 3: |(150 - 130) / 150| [cite$_s$tart] x 100% = 13,3%
4. APE 4: |(30 - 35) / 30|[cite$_s$tart] x 100% =16,7%
5. APE 5: |(60 - 55) / 60|[cite$_s$tart] x 100% = 8,3%

MAPE = (12,0 + 10,0 + 13,3 + 16,7 + 8,3) / 5 = 12,06%

4.2.3. *Perhitungan RMSE*

Kuadrat error dihitung untuk setiap titik data guna menekankan besarnya deviasi prediksi dari nilai aktual. Penggunaan *Mean Squared Error* (*MSE*) sebagai rata-rata kuadrat error memberikan ukuran kesalahan yang lebih sensitif terhadap outlier. Akar kuadrat dari MSE menghasilkan *Root Mean Square Error* (*RMSE*), yang memudahkan interpretasi kesalahan dalam satuan yang sama dengan variabel yang diukur. Menggunakan data sampel hipotetis pada Tabel 3, hasil perhitungan Kuadrat Error dan rata-ratanya (MSE), serta RMSE, disajikan sebagai berikut:

1. Kuadrat Error 1: $(25 - 28)^2 = 9$
2. Kuadrat Error 2: $(50 – 45)^2 = 25$
3. Kuadrat Error 3: $(150 - 130)^2 = 400$
4. Kuadrat Error 4: $(30 - 35)^2 = 25$
5. Kuadrat Error 5: $(60 - 55)^2 = 25$

MSE (rata-rata kuadrat *error*) = (9 + 25 + 400 + 25 + 25) / 5 = 96,8

RMSE $\sqrt{96,8} = 9,84$

5. DISKUSI

Hasil penelitian ini secara jelas menunjukkan bahwa Model Prediksi Cuaca Hibrida Adaptif yang dikembangkan memiliki kinerja yang jauh lebih unggul dibandingkan pendekatan model tunggal, baik SARIMA maupun LSTM. Keunggulan tersebut didukung oleh dua aspek utama, yaitu kemampuan dalam melakukan klasifikasi pola cuaca dan mekanisme prediksi yang bersifat adaptif. Pendekatan konvensional yang menggunakan satu model untuk seluruh jenis data terbukti kurang efektif ketika diterapkan pada kondisi cuaca di Indonesia yang sangat bervariasi dan dinamis. Berdasarkan hasil evaluasi, model SARIMA tidak mampu menangani lonjakan data ekstrem yang bersifat non-linear [1]. Di sisi lain, meskipun LSTM memiliki kemampuan yang kuat dalam mempelajari pola kompleks, model ini menjadi kurang efisien ketika digunakan untuk data musiman yang relatif sederhana dan dapat dijelaskan dengan metode statistik yang lebih ringan [2].

Model hibrida yang dikembangkan dalam penelitian ini mampu mengatasi kelemahan pendekatan tunggal dengan cara terlebih dahulu *memahami konteks data* melalui proses klasifikasi pola. Setelah data diidentifikasi sebagai pola normal atau ekstrem, sistem secara cerdas memilih "ahli" yang paling sesuai untuk melakukan prediksi: model SARIMA digunakan untuk pola cuaca yang bersifat musiman dan teratur, sedangkan LSTM diaktifkan untuk menangani pola anomali yang kompleks dan non-linear. Pendekatan ini sejalan dengan temuan dari penelitian sebelumnya yang juga menunjukkan keunggulan model hibrida, seperti kombinasi ARIMA-RNN [8] dan SARIMA-LSTM [9]. Namun, model yang kami kembangkan memiliki keunggulan tambahan berupa mekanisme pemilihan yang adaptif, yang memungkinkan sistem menyesuaikan pendekatan pemodelan secara otomatis berdasarkan karakteristik pola cuaca yang terdeteksi.

Dari sudut pandang mitigasi bencana, kemampuan model ini dalam menurunkan nilai *RMSE* secara signifikan menjadi salah satu kontribusi paling penting. Nilai *RMSE* yang rendah (9,13) menunjukkan bahwa model tidak hanya mampu memprediksi kapan hujan akan terjadi, tetapi juga seberapa besar intensitas curah hujan ekstrem dengan tingkat kesalahan yang sangat kecil. Tingkat akurasi yang tinggi pada prediksi kejadian ekstrem ini memiliki peran krusial dalam pengembangan sistem peringatan dini (early warning system) yang

p-ISSN : 2803-1507 e-ISSN : 2803-1531

andal. Sistem semacam ini dapat memberikan informasi penting bagi lembaga seperti BMKG dan BPBD untuk melakukan tindakan pencegahan sebelum bencana seperti banjir atau tanah longsor terjadi [4]. Secara praktis, peningkatan akurasi ini berimplikasi langsung pada kualitas informasi cuaca yang diterima publik maupun pembuat kebijakan. Dengan demikian, hasil penelitian ini berpotensi mendukung perencanaan sumber daya air yang lebih baik serta memperkuat upaya mitigasi bencana di berbagai wilayah Indonesia.

6. KESIMPULAN DAN SARAN

6.1 *Kesimpulan*

Hasil-hasil yang diperoleh dari penelitian ini memberikan gambaran yang lebih jelas mengenai efektivitas pendekatan yang digunakan dalam memodelkan dinamika cuaca. Temuan tersebut menunjukkan adanya kecenderungan peningkatan performa prediksi ketika model mampu menyesuaikan diri dengan variasi pola data yang muncul. Evaluasi terhadap kinerja model juga memperlihatkan bahwa perbedaan karakteristik cuaca memiliki pengaruh besar terhadap pemilihan metode prediksi yang paling tepat. Secara keseluruhan, rangkaian hasil tersebut memberikan dasar yang kuat untuk mengidentifikasi poin-poin utama yang menjadi capaian penting dalam penelitian ini. Berdasarkan hasil analisis dan evaluasi yang telah dilakukan selama penelitian, terdapat beberapa poin penting yang dapat disimpulkan sebagai berikut:

1. Model Hibrida Adaptif Lebih Unggul
   Hasil penelitian ini menunjukkan bahwa Model Hibrida Adaptif, yang menggabungkan proses klasifikasi pola menggunakan algoritma *K-Means* dengan dua model prediksi spesialis, yaitu SARIMA dan LSTM, mampu memberikan kinerja yang jauh lebih baik dibandingkan model tunggal. Dengan capaian nilai MAPE sebesar 8,76% dan RMSE sebesar 9,13, model ini terbukti memiliki tingkat akurasi yang sangat tinggi serta mampu menurunkan kesalahan prediksi lebih dari 50% dibandingkan model pembanding (*baseline*). Penerapan pendekatan *unsupervised learning* seperti *K-Means* memberikan kemampuan tambahan bagi sistem untuk mengidentifikasi pola sebelum proses peramalan dilakukan. Integrasi dua model prediktif ini juga memberikan stabilitas performa pada berbagai kondisi data yang berfluktuasi.
2. Pentingnya Klasifikasi Pola
   berhasilan model ini sangat dipengaruhi oleh kemampuannya dalam mengklasifikasikan pola cuaca sebelum proses prediksi dilakukan. Dengan membedakan antara pola normal atau musiman dan pola ekstrem atau non-linear, sistem dapat secara cerdas memilih metode prediksi yang paling sesuai untuk setiap kondisi. Pendekatan ini membuat model lebih fleksibel dan adaptif sehingga mampu mengatasi keterbatasan model tunggal yang sering gagal menyesuaikan diri dengan dinamika cuaca yang kompleks. Pendekatan tersebut juga memberikan ruang bagi sistem untuk menyesuaikan strategi prediksi secara dinamis terhadap variasi cuaca dalam rentang waktu tertentu.
3. Kontribusi terhadap Mitigasi Bencana
   Kemampuan model ini dalam memprediksi intensitas curah hujan ekstrem dengan tingkat kesalahan yang sangat rendah menjadi salah satu kontribusi paling penting dalam upaya mitigasi bencana. Tingkat akurasi yang tinggi tersebut berperan besar dalam pengembangan sistem peringatan dini (*early warning system*) yang andal, yang dapat memberikan informasi penting bagi lembaga terkait untuk mengambil langkah-langkah preventif sebelum bencana hidrometeorologi, seperti banjir atau tanah longsor, terjadi. Informasi prediktif yang lebih presisi membantu lembaga terkait dalam menentukan tindakan antisipatif secara lebih terstruktur. Penerapan model ini juga meningkatkan keandalan proses monitoring sehingga potensi risiko dapat dikenali lebih awal.

6.2 *Saran*

Berdasarkan hasil temuan serta beberapa keterbatasan yang masih ada dalam penelitian ini, terdapat beberapa arah pengembangan yang dapat dilakukan di masa mendatang. Untuk meningkatkan akurasi dan sensitivitas model, disarankan agar penelitian berikutnya mengintegrasikan variabel iklim tambahan, seperti tekanan udara dan data citra satelit. Selain itu, validasi model perlu diperluas dengan menggunakan *dataset* dari berbagai wilayah di Indonesia agar diperoleh hasil yang lebih umum (*generalisable*) dan tahan uji (*robust*) terhadap perbedaan kondisi cuaca. Dari sisi penerapan praktis, Model Hibrida Adaptif ini memiliki potensi besar untuk dikembangkan menjadi sistem peramalan cuaca real-time yang terintegrasi dengan platform milik BMKG atau BPBD. Sistem ini berpotensi memperluas pemanfaatan informasi prediktif sehingga proses pengambilan keputusan operasional dapat didukung dengan data yang lebih terstruktur.

DAFTAR PUSTAKA

p-ISSN : 2803-1507 e-ISSN : 2803-1531

[1] H. Hikmah, A. Asrirawan, A. Apriyanto, and N. Nilawati, "Peramalan Data Cuaca Ekstrim Indonesia Menggunakan Model ARIMA dan Recurrent Neural Network," *Jambura J. Math.*, vol. 5, no. 1, pp. 230–242, Feb. 2023, doi: 10.34312/jjom.v5i1.17496.

[2] D. Kurniasari, A. D. Salsabila, M. Usman, and Warsono, "Enhancing Weather Forecasting in Bandar Lampung: A Hybrid SARIMA-LSTM Approach," *JTAM (Jurnal Teor. dan Apl. Mat.*, vol. 9, no. 1, pp. 206–220, 2025, doi: 10.31764/jtam.v9i1.27188.

[3] Uliyatunisa and D. Supriatna, "Komparasi Model LSTM dan CNN-LSTM untuk Peramalan Curah Hujan di Kota Tangerang Selatan," *Bull. Inf. Technol.*, vol. 6, no. 3, pp. 294–301, Sep. 2025, doi: 10.47065/bit.v6i3.2235.

[4] G. M. L. Gaol, M. Syafrullah, and S. Supardi, "Comparison of Monthly Rainfall Prediction using Long Short Term Memory and Multi Layer Perceptron Methods in South Tangerang City," *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 13, no. 2, pp. 293–297, Jun. 2024, doi: 10.32736/sisfokom.v13i2.2149.

[5] D. Supriatna, S. Anggai, and Tukiyat, "Analisis Prediksi Curah Hujan di Kota Tangerang Menggunakan Metode LSTM dan GRU," *J. Pustaka AI (Pusat Akses Kaji. Teknol. Artif. Intell.*, vol. 5, no. 2, pp. 119–131, Aug. 2025, doi: 10.55382/jurnalpustakaai.v5i2.1068.

[6] R. F. Firdaus and I. V. Paputungan, "Prediksi Curah Hujan di Kota Bandung Menggunakan Metode Long Short Term Memory," *J. Penelit. Inov.*, vol. 2, no. 3, pp. 453–460, Nov. 2022, doi: 10.54082/jupin.99.

[7] P. E. Sandya S, R. P. Patria, D. P. Bergas, M. Ahsanur Rafi, and A. Puspita Sari, "Implementasi JST Untuk Memprediksi Cuaca Dengan Menggunakan Model RNN dan LSTM," in *Seminar Nasional Informatika Bela Negara (SANTIKA)*, 2023, pp. 2747–0563. [Online]. Available: https://santika.upnjatim.ac.id/submissions/index.php/santika/article/view/204

[8] E. Supriyadi, "Prediksi Parameter Cuaca Menggunakan Deep Learning Long-Short Term Memory (LSTM)," *J. Meteorol. dan Geofis.*, vol. 21, no. 2, pp. 55–67, Jan. 2020, doi: 10.31172/jmg.v21i2.619.

[9] F. D. Rahman, M. I. Z. Mulki, and A. Taryana, "Clustering dan Klasifikasi Data Cuaca Cilacap Dengan Menggunakan Metode K-Means dan Random Forest," *J. SINTA Sist. Inf. dan Teknol. Komputasi*, vol. 1, no. 2, pp. 90–97, Apr. 2024, doi: 10.61124/sinta.v1i2.15.

[10] M. Z. Arkananta, Y. Darmawan, M. E. Trianasari, W. Widodo, and A. Widodo, "Perbandingan Model Prediksi Curah Hujan Kota Semarang: Metode SARIMA dan Holt-Winter ," 2025. doi: 10.29313/jrs.v5i1.6149.

[11] N. Rahmeisi, E. umar Gani, and A. Arfriandi, "Tinjauan Literatur: Pendekatan Machine Learning dalam Deteksi Serangan Web," *J. Ilm. Sist. Inf.*, vol. 4, no. 3, pp. 772–791, Nov. 2025, doi: 10.51903/3w0vwc80.

[12] Suwardi, S. H. Prasastono, S. K. Sudibyo, and T. Sumarlin, "Predicting Stock Price Movements Using Deep Learning: An Analysis of Machine Learning Models for Portfolio Optimization," *J. Manag. Informatics*, vol. 3, no. 3, pp. 490–510, Dec. 2024, doi: 10.51903/jmi.v3i3.57.

[13] A. R. Rudiyanto, B. P. Satria, and H. D. Panjaitan, "Optimization of Smart Home Energy Consumption Using Machine Learning-Based Load Forecasting," *J. Technol. Informatics Eng.*, vol. 4, no. 2, pp. 300–316, Aug. 2025, doi: 10.51903/jtie.v4i2.437.

[14] D. Wahyudi and I. V. Paputungan, "Pemodelan Curah Hujan pada Kota Bengkulu menggunakan Seasonal Autoregressive Integrated Moving Average (SARIMA)," *Automata*, vol. 3, no. 2, pp. 82–88, 2022, [Online]. Available: https://journal.uii.ac.id/automata/article/view/24319

[15] S. Mukarom, C. A. Siregar, and A. A. R. Pratiwi, "Pemodelan Hidrologi dan Hidrolika untuk Mitigasi Banjir Studi Kasus di Daerah Aliran Sungai Citanduy Hulu Kecamatan Panumbangan Kabupaten Ciamis," *J. Media Teknol.*, vol. 12, no. 1, pp. 189–198, 2025, doi: 10.25157/jmt.v12i1.5243.

[16] R. C. H. Hutauruk *et al.*, "Evaluation of Bias Correction Method for Monthly Rainfall Prediction of ECMWF SEAS5 in Indonesia," *J. Meteorol. dan Geofis.*, vol. 25, no. 2, pp. 103–112, Jun. 2024, doi:

p-ISSN : 2803-1507 e-ISSN : 2803-1531

10.31172/jmg.v25i2.1124.

[17] A. V. Wulandari1, N. J. Trilaksono, and M. Ryan, "Improving Short-Term Weather Forecasting using Support Vector Machine Method in North Barito," *J. Meteorol. dan Geofis.*, vol. 25, no. 2, pp. 113–121, Jun. 2024, doi: 10.31172/jmg.v25i2.1096.

[18] A. Fauziah, H. Hermanto, and M. A. Sukmarini, "Extreme Gradient Boosting pada Peramalan Pola Curah Hujan Bulanan Kabupaten Banyuwangi," *J. Kridatama Sains dan Teknol.*, vol. 6, no. 02, pp. 430–440, Jul. 2024, doi: 10.53863/kst.v6i02.1154.

[19] A. Riski, A. Kamsyakawuni, and C. R. Azhar, "Peramalan Curah Hujan Harian Kabupaten Jember dengan Jaringan Saraf Tiruan dan General Circulation Model," *J Stat. J. Ilm. Teor. dan Apl. Stat.*, vol. 16, no. 1, pp. 309–315, Jul. 2023, doi: 10.36456/jstat.vol16.no1.a7862.

[20] A. Pakkung, D. Hatidja, and J. Titaley, "Prediksi Curah Hujan Kota Manado Dengan Menggunakan Metode Autoregressive Moving Average (ARMA)," *d'Cartesian*, vol. 13, no. 1, pp. 11–16, Mar. 2024, doi: 10.35799/dc.13.1.2024.53780.

[21] E. Supriyadi, "Estimation of Daily Weather Data by Generating Monthly Data: North Sulawesi Case Study ," 2024. doi: 10.31172/jmg.v24i2.718.

[22] Y. M. Andariwan, N. S. Ningsih, and A. R. Kartadikaria, "Numerical Simulation of Waves in The North Sulawesi Waters using Swan Wave Model," *J. Meteorol. dan Geofis.*, vol. 25, no. 2, pp. 93–101, Jun. 2024, doi: 10.31172/jmg.v25i2.1104.

[23] R. Wicaksono, J. D. Irawan, and S. A. Wibowo, "Sistem Peramalan Curah Hujan Menggunakan Metode Regresi Linier Berganda Berbasis IOT," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 4, pp. 2103–2112, Dec. 2023, doi: 10.36040/jati.v7i4.7350.

[24] N. M. Hidayat, R. Hidayati, A. Turyanti, and S. F. Al Maula, "Modification of The Thermal Comfort Index Based on Perceptions for Urban Tourism Around Jakarta," *J. Meteorol. dan Geofis.*, vol. 25, no. 1, pp. 1–15, Aug. 2024, doi: 10.31172/jmg.v25i1.1051.

[25] S. Andriani, D. M. Akhmad, and F. D. Wihartiko, "Pemodelan Monte Carlo untuk Prediksi Sifat Hujan Harian," *Comput. J. Comput. Sci. Inf. Syst.*, vol. 4, no. 2, pp. 124–135, Dec. 2020, doi: 10.24912/computatio.v4i2.9697.

[26] D. Patil and K. Alaskar, *A Hybrid Approach for Rainfall Prediction: Leveraging Prophet for Seasonality And Light GBM for Residuals*, 1st ed. CRC Press, 2025. doi: 10.1201/9781003650010-56.