



Optimalisasi Akurasi Prediksi Curah Hujan Bulanan Menggunakan Deep Learning

Muhammad Ikrom Yafik¹, Chairani Chairani^{2,*}

¹ Fakultas Ilmu Komptuer, Program Studi Ilmu Komputer, Institut Informatika Dan Bisnis Darmajaya, Bandar Lampung, Indonesia

² Fakultas Ilmu Komputer, Program Studi Magister Teknik Informatika, Institut Informatika Dan Bisnis Darmajaya, Bandar Lampung, Indonesia

Email: ¹ikrom.2321211019@mail.darmajaya.ac.id, ^{2,*}chairani@darmajaya.ac.id

Email Penulis Korespondensi: chairani@darmajaya.ac.id

Abstrak—Provinsi Lampung memiliki variabilitas curah hujan yang tinggi yang dipengaruhi oleh berbagai faktor dinamika atmosfer seperti Monsun Asia, Monsun Australia, El Niño-Southern Oscillation (ENSO), dan Indian Ocean Dipole (IOD). Prediksi curah hujan yang akurat sangat penting dalam berbagai sektor, termasuk pertanian, pengelolaan sumber daya air, serta mitigasi bencana hidrometeorologi. Namun, metode prediksi yang umum digunakan di wilayah ini masih didominasi oleh pendekatan statistik atau machine learning konvensional yang sering kurang mampu menangkap pola temporal jangka panjang pada data curah hujan. Di sisi lain, teknologi *deep learning* seperti Recurrent Neural Network (RNN) dan Gated Recurrent Unit (GRU) menawarkan kemampuan lebih baik dalam memodelkan data deret waktu, tetapi belum pernah dilakukan evaluasi komparatif secara spesifik untuk prediksi curah hujan di Provinsi Lampung. Perbandingan kedua metode ini menjadi penting karena karakteristik arsitektur RNN dan GRU berbeda dalam menangani *long-term dependencies*, sehingga pemilihan model yang tepat dapat berdampak langsung pada peningkatan akurasi prediksi dan efektivitas pengambilan keputusan di sektor terdampak. Penelitian ini bertujuan mengimplementasikan dan membandingkan kinerja RNN dan GRU untuk memprediksi curah hujan bulanan di Provinsi Lampung menggunakan data dari 80 pos hujan yang tersebar di 15 kabupaten/kota selama periode Januari 1991 hingga Februari 2025. Hasil penelitian menunjukkan bahwa model RNN lebih unggul dibandingkan GRU, dengan nilai RMSE lebih rendah (115.61 vs. 119.50), MAE lebih kecil (86.94 vs. 91.28), serta R² lebih tinggi (0.35 vs. 0.30). Prediksi untuk periode Maret 2025 – Februari 2026 memperlihatkan pola musiman yang jelas, dengan curah hujan minimum pada Agustus 2025 (puncak musim kemarau) dan maksimum pada Januari 2026 (puncak musim hujan). Penelitian ini menunjukkan bahwa RNN lebih efektif dalam menangkap pola temporal curah hujan dibandingkan GRU, sehingga lebih direkomendasikan untuk aplikasi prediksi jangka panjang.

Kata Kunci: Prediksi Curah Hujan; RNN; GRU; Deep Learning; Lampung; Hidrometeorologi

Abstract—The Province of Lampung exhibits high rainfall variability influenced by various atmospheric dynamics such as the Asian Monsoon, Australian Monsoon, El Niño–Southern Oscillation (ENSO), and the Indian Ocean Dipole (IOD). Accurate rainfall prediction is crucial across multiple sectors, including agriculture, water resource management, and hydrometeorological disaster mitigation. However, prediction methods commonly used in the region are still dominated by statistical approaches or conventional machine learning techniques, which often struggle to capture long-term temporal patterns in rainfall data. On the other hand, deep learning technologies such as the Recurrent Neural Network (RNN) and Gated Recurrent Unit (GRU) offer better capabilities in modeling time series data, yet no specific comparative evaluation has been conducted for rainfall prediction in the Lampung Province. Comparing these two methods is important because the architectural characteristics of RNN and GRU differ in handling long-term dependencies, and selecting the right model can directly impact prediction accuracy and the effectiveness of decision-making in affected sectors. This study aims to implement and compare the performance of RNN and GRU in predicting monthly rainfall in Lampung Province using data from 80 rain gauges distributed across 15 districts/cities over the period from January 1991 to February 2025. The results show that the RNN model outperforms the GRU model, with lower RMSE (115.61 vs. 119.50), smaller MAE (86.94 vs. 91.28), and higher R² (0.35 vs. 0.30). Predictions for the period from March 2025 to February 2026 reveal a clear seasonal pattern, with minimum rainfall occurring in August 2025 (peak dry season) and maximum rainfall in January 2026 (peak rainy season). This study demonstrates that RNN is more effective than GRU in capturing the temporal patterns of rainfall, making it more recommended for long-term prediction applications.

Keywords: Rainfall Prediction; RNN; GRU; Deep Learning; Lampung; Hydrometeorology

1. PENDAHULUAN

Provinsi Lampung merupakan salah satu wilayah di Indonesia yang memiliki variabilitas curah hujan tinggi. Letaknya di ujung selatan Pulau Sumatera membuatnya dipengaruhi oleh berbagai faktor atmosferik seperti Monsun Asia, Monsun Australia, *cold surge*, serta fenomena iklim global seperti El Niño–Southern Oscillation (ENSO) dan Indian Ocean Dipole (IOD). Prediksi curah hujan yang akurat di wilayah ini sangat penting untuk mendukung keberlangsungan sektor pertanian, pengelolaan sumber daya air, transportasi, serta mitigasi bencana banjir dan kekeringan. Meskipun berbagai metode prediksi telah dikembangkan, pendekatan yang umum digunakan masih didominasi oleh model statistik atau *machine learning* konvensional yang sering kali kurang mampu menangkap pola temporal jangka panjang dan variabilitas ekstrem curah hujan di daerah tropis. Beberapa penelitian telah menerapkan *deep learning* untuk prediksi cuaca di wilayah Indonesia, namun belum banyak yang secara khusus membandingkan performa Recurrent Neural Network (RNN) dan Gated Recurrent Unit (GRU) pada data curah hujan jangka panjang dengan resolusi spasial tinggi di Provinsi Lampung [15], [16]. Penelitian serupa yang dilakukan di lingkungan akademik IBI Darmajaya juga membuktikan efektivitas *deep learning* dalam memprediksi pola hujan dan iklim tropis di Provinsi Lampung [19], [20]. Kebaruan penelitian ini terletak pada evaluasi komparatif kedua arsitektur tersebut dengan dataset multi-pos hujan selama lebih dari tiga dekade, untuk mengidentifikasi model yang paling efektif dalam menangkap pola musiman dan ekstremitas curah hujan di Lampung,



sehingga dapat memberikan kontribusi nyata pada peningkatan akurasi prediksi dan pengambilan keputusan di sektor terdampak.

Di antara berbagai metode deep learning, Recurrent Neural Network (RNN) dan Gated Recurrent Unit (GRU) telah menjadi pilihan yang populer dalam memprediksi data deret waktu, termasuk curah hujan bulanan. RNN dikenal dengan kemampuannya dalam menangani dependensi jangka panjang dalam data berurutan, sehingga sangat cocok untuk memprediksi curah hujan dengan pola musiman dan fluktuasi tinggi. Menurut penelitian yang dilakukan oleh Latifoğlu, model RNN dapat secara efektif mengidentifikasi pola curah hujan menggunakan data historis dan menunjukkan hasil prediksi yang lebih akurat dibandingkan metode konvensional [1]. Selain itu, studi yang dilakukan oleh Saleem dkk, menunjukkan bahwa kombinasi RNN dan GRU yang dioptimalkan dapat meningkatkan akurasi prediksi suhu dan kelembaban [2]. Penelitian lainnya yang dilakukan oleh Carnegie dkk, menunjukkan bahwa model RNN dengan pembagian dataset 7:3 memiliki performa terbaik dalam memprediksi curah hujan di Stasiun Geofisika Lampung Utara, dengan nilai RMSE 16,81, MSE 282,55, dan MAD 10,43 [3].

Gated Recurrent Unit (GRU), sebagai varian dari RNN juga menawarkan arsitektur model yang lebih sederhana dengan performa yang kompetitif dalam pemrosesan data deret waktu. Keunggulan utama GRU terletak pada kemampuannya mengatasi masalah vanishing gradient dengan jumlah parameter yang lebih sedikit dibandingkan RNN, sehingga dapat meningkatkan efisiensi komputasi tanpa mengorbankan akurasi prediksi. Studi terbaru telah menunjukkan bahwa GRU mampu memberikan hasil yang menjanjikan dalam peramalan cuaca, terutama dalam skala temporal jangka panjang [2]. Studi yang dilakukan oleh Surta dkk, dalam memprediksi curah hujan harian di Kota Palembang menunjukkan bahwa model RNN memiliki nilai RMSE 7,45 dan R^2 0,70, sedangkan model GRU memiliki nilai RMSE 9,33 dan R^2 0,54, mengindikasikan bahwa RNN memberikan hasil prediksi yang lebih akurat dibandingkan GRU [4], [17], [18].

Seiring berkembangnya metode prediksi curah hujan berbasis *deep learning*, masih diperlukan evaluasi komparatif untuk menilai performa model dalam berbagai skenario meteorologi. Penelitian ini mengimplementasikan dan membandingkan *Recurrent Neural Network* (RNN) dan *Gated Recurrent Unit* (GRU) untuk memprediksi curah hujan bulanan di Provinsi Lampung menggunakan dataset multi-pos hujan yang komprehensif. Selama ini, prediksi curah hujan di wilayah ini umumnya mengandalkan metode statistik atau *machine learning* konvensional seperti regresi linier, ARIMA, dan *support vector regression*, yang meskipun mampu menangkap pola umum, sering menghasilkan galat tinggi pada periode transisi musim atau saat anomali iklim seperti El Niño dan IOD positif. Oleh karena itu, penelitian ini berkontribusi dalam meningkatkan akurasi prediksi dengan memanfaatkan *deep learning*, sehingga dapat mendukung pengambilan keputusan di sektor pertanian, pengelolaan sumber daya air, mitigasi bencana hidrometeorologi, serta menjadi acuan pengembangan metode yang lebih canggih untuk wilayah lain dengan karakteristik iklim berbeda.

2. METODOLOGI PENELITIAN

2.1 Deep Learning

Deep learning merupakan cabang *machine learning* yang memanfaatkan jaringan saraf tiruan berlapis banyak (*deep neural networks*) untuk mengekstraksi pola kompleks dari data, termasuk data meteorologi [5]. Dalam konteks prediksi curah hujan bulanan, arsitektur yang umum digunakan adalah *Recurrent Neural Network* (RNN) dan turunannya seperti *Gated Recurrent Unit* (GRU), yang dirancang untuk mengolah data sekuensial dan menangkap ketergantungan temporal pada deret waktu curah hujan [6]. Model ini bekerja melalui propagasi maju (*forward propagation*) dan pembaruan bobot menggunakan propagasi balik (*backpropagation*) dengan algoritma optimasi seperti *gradient descent*, serta memanfaatkan fungsi aktivasi non-linear seperti ReLU untuk meningkatkan kemampuan representasi [7]. Pada RNN, pembaruan sel memori melibatkan mekanisme gerbang (*gates*) yang mengatur informasi yang disimpan dan dilupakan, sehingga model dapat mempertahankan pola musiman maupun kejadian ekstrem dari data historis. Selain itu, perkembangan terbaru seperti *Transformer* dan *Attention Mechanism* telah menunjukkan potensi peningkatan akurasi prediksi hujan dengan menangkap hubungan spasial antarwilayah dan temporal lintas musim secara lebih efektif, sehingga relevan untuk pengembangan model prediksi curah hujan di Provinsi Lampung. [8], [9].

2.2 Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) merupakan arsitektur *deep learning* yang dirancang untuk memproses data sekuensial dan menangkap ketergantungan temporal, sehingga relevan untuk prediksi curah hujan bulanan yang dipengaruhi pola musiman dan anomali iklim seperti El Niño dan IOD [8]. Dalam konteks ini, RNN menggunakan unit memori dengan mekanisme gerbang, yaitu *forget gate* untuk menentukan informasi yang dihapus, *input gate* untuk mengatur informasi baru yang masuk, dan *output gate* untuk menghasilkan keluaran tersembunyi yang digunakan dalam prediksi. Proses pembaruan sel memori mengombinasikan informasi historis dan masukan baru, memungkinkan model mempertahankan pola hujan jangka panjang serta mereduksi masalah *vanishing gradient*. Keunggulan RNN pada prakiraan curah hujan terletak pada kemampuannya mempelajari hubungan kompleks antara data historis hujan dengan faktor meteorologis lain seperti tekanan atmosfer, kelembapan, dan suhu permukaan laut. Selain itu, penggabungan RNN dengan teknik seperti *Attention Mechanism* atau *Convolutional Neural Networks* (CNN) dapat meningkatkan akurasi prediksi, khususnya dalam mendeteksi perubahan pola curah hujan yang ekstrem maupun musiman di Provinsi Lampung [10], [11].



2.3 Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) merupakan varian dari *Recurrent Neural Network (RNN)* yang dirancang untuk mengatasi masalah *vanishing gradient* sekaligus meningkatkan efisiensi komputasi, sehingga cocok untuk prediksi curah hujan bulanan yang membutuhkan pengolahan data deret waktu jangka panjang [12]. Berbeda dengan RNN standar, GRU hanya menggunakan dua gerbang utama, yaitu *update gate* untuk menentukan proporsi informasi historis yang dipertahankan, dan *reset gate* untuk mengatur seberapa banyak informasi lama yang diabaikan. Mekanisme ini memungkinkan GRU fokus pada pola curah hujan yang relevan, termasuk variabilitas musiman maupun anomali iklim seperti El Niño dan IOD, dengan jumlah parameter lebih sedikit dibanding RNN, sehingga pelatihan model menjadi lebih cepat. Dalam penelitian meteorologi, GRU dapat memproses variabel input seperti curah hujan, kelembapan udara, dan tekanan atmosfer, lalu memadukan informasi lama dan kandidat informasi baru untuk menghasilkan *hidden state* yang diperbarui secara dinamis pada setiap langkah waktu [13]. Sifat efisien ini menjadikan GRU unggul pada aplikasi prediksi cuaca di daerah dengan sumber daya komputasi terbatas, tanpa mengorbankan kemampuan model dalam menangkap pola hubungan jangka panjang pada data curah hujan [14].

2.4 Pengumpulan Data

Data yang digunakan dalam penelitian ini berupa curah hujan bulanan hasil akumulasi pengamatan harian dari 80 pos hujan yang tersebar di 15 kabupaten/kota di Provinsi Lampung, mencakup variasi geografis dari wilayah pesisir, dataran rendah, hingga perbukitan. Pengukuran dilakukan setiap pukul 07.00 WIB menggunakan gelas ukur standar sesuai pedoman WMO dan BMKG, kemudian dilaporkan melalui sistem *Elektronik Pelaporan Hujan Klimatologi (ePHK)*. Data yang dikumpulkan mencakup periode Januari 1991–Februari 2025, dengan data 1991–2018 digunakan untuk pelatihan model dan 2019–2025 untuk pengujian, sehingga mencakup pola musiman, variabilitas iklim jangka panjang, serta kejadian ekstrem seperti El Niño dan La Niña. Proses verifikasi dilakukan untuk mengidentifikasi data hilang atau tidak wajar, yang kemudian diinterpolasi menggunakan metode *Inverse Distance Weighting (IDW)* atau Kriging jika diperlukan. Data disimpan dalam format CSV bernama *dataprediksi.csv* dengan struktur kolom tahun, bulan, dan nilai curah hujan per pos (mm), yang kompatibel untuk pengolahan lebih lanjut menggunakan perangkat lunak analisis data dan penerapan model *deep learning*. Cakupan data yang luas dan terstandar ini diharapkan mampu merepresentasikan kondisi curah hujan di seluruh wilayah Lampung secara akurat, sehingga mendukung pengembangan model prediksi yang andal. Gambar 1 menampilkan gelas ukur yang digunakan pengamatan pos hujan untuk mengukur curah hujan yang jatuh selama 24 jam terakhir, sedangkan Tabel 1 menunjukkan data yang digunakan untuk pelatihan dan pengujian model prediksi Deep Learning di 80 pos hujan yang tersebar di wilayah Lampung mulai tahun 1991 sampai tahun 2025.



Gambar 1. Gelar Ukur Penakar Hujan Observasi

Tabel 1. Sampe Data Hujan Bulanan

Tahun	Bulan	246z	246	228c	228t	218b	219c	219d	218c
1991-01	Jan	486	486	547	547	266	293	238	238
1991-02	Feb	247	247	271	271	102	167	566	566
1991-03	Mar	255	255	457	457	21	359	307	307
1991-04	Apr	258	258	354	354	31	381	370	370
1991-05	May	142	142	97	97	17	372	173	173
1991-06	Jun	36	36	4	4	0	160	91	91
1991-07	Jul	22	22	0	0	2	138	192	192
1991-08	Aug	0	0	3	3	13	380	223	223
1991-09	Sep	0	0	62	62	42	328	112	112
1991-10	Oct	91	91	5	5	174	534	91	91



Tahun	Bulan	246z	246	228c	228t	218b	219c	219d	218c
1991-11	Nov	218	218	270	270	212	356	118	118
1991-12	Dec	361	361	473	473	211	361	143	143
				dst					
2024-01	Jan	288	181	240	403	401	279	486	276
2024-02	Feb	392	396	397	200	287	247	299	324
2024-03	Mar	314	390	301	336	271	227	306	174
2024-04	Apr	192	253	184	266	473	342	483	355
2024-05	May	178	174	135	111	510	320	383	243
2024-06	Jun	50	87	96	64	149	203	261	151
2024-07	Jul	74	42	74	68	144	51	81	38
2024-08	Aug	43	14	21	84	42	79	64	60
2024-09	Sep	263	121	97	92	286	191	149	134
2024-10	Oct	78	68	26	60	147	89	147	92
2024-11	Nov	156	132	124	106	40	124	161	229
2024-12	Dec	568	240	275	212	129	96	352	40
2025-01	Jan	607	462	427	333	493	325	559	372
2025-02	Feb	323	493	226	200	183	148	416	191

2.5 Implementasi Model RNN dan GRU

Penelitian ini mengimplementasikan dua arsitektur *deep learning*, yaitu *Recurrent Neural Network* (RNN) dan *Gated Recurrent Unit* (GRU), untuk memprediksi curah hujan bulanan di Provinsi Lampung berdasarkan data dari 80 pos hujan. Data yang telah dikompilasi dalam *dataprediksi.csv* diproses di Google Colab melalui tahapan *preprocessing* meliputi konversi format tanggal, imputasi nilai hilang dengan rata-rata kolom, normalisasi menggunakan *MinMaxScaler*, pembentukan *sequence* sepanjang 12 bulan sebagai input, dan pembagian data menjadi 80% latih dan 20% uji. Arsitektur RNN terdiri dari dua lapisan RNN (100 unit dan 50 unit) dengan *dropout* 20% dan *Dense layer* pada keluaran, sedangkan GRU menggunakan satu lapisan GRU 100 unit atau alternatif *BiLSTM* 100 unit, *dropout* 20%, dan *Batch Normalization*. Kedua model dioptimasi menggunakan Adam dengan *loss function* MSE, dilatih selama 50 *epoch* dengan *batch size* 16, lalu dievaluasi menggunakan RMSE, MAE, dan R^2 . Hasil prediksi model disimpan dalam format CSV, sedangkan model terlatih disimpan dalam format HDF5 (.h5) untuk penggunaan kembali tanpa pelatihan ulang.

2.6 Metode Evaluasi Model

Evaluasi kinerja model *Recurrent Neural Network* (RNN) dan *Gated Recurrent Unit* (GRU) dilakukan menggunakan tiga metrik utama, yaitu *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *R-squared* (R^2). RMSE mengukur rata-rata kesalahan prediksi terhadap nilai aktual dalam skala asli data dengan memberikan bobot lebih besar pada kesalahan besar, sedangkan MAE mengukur rata-rata kesalahan absolut tanpa mengkuadratkan selisih, sehingga lebih tahan terhadap *outlier* dan mudah diinterpretasikan karena satuannya sama dengan data asli. R^2 digunakan untuk menilai proporsi variabilitas data yang dapat dijelaskan oleh model, dengan nilai mendekati 1 menunjukkan kinerja prediksi yang baik, meskipun perlu dianalisis bersama RMSE dan MAE untuk menghindari indikasi *overfitting*. Kombinasi ketiga metrik ini memberikan gambaran menyeluruh mengenai akurasi, robustnes, dan kemampuan generalisasi model dalam memprediksi curah hujan bulanan di Provinsi Lampung.

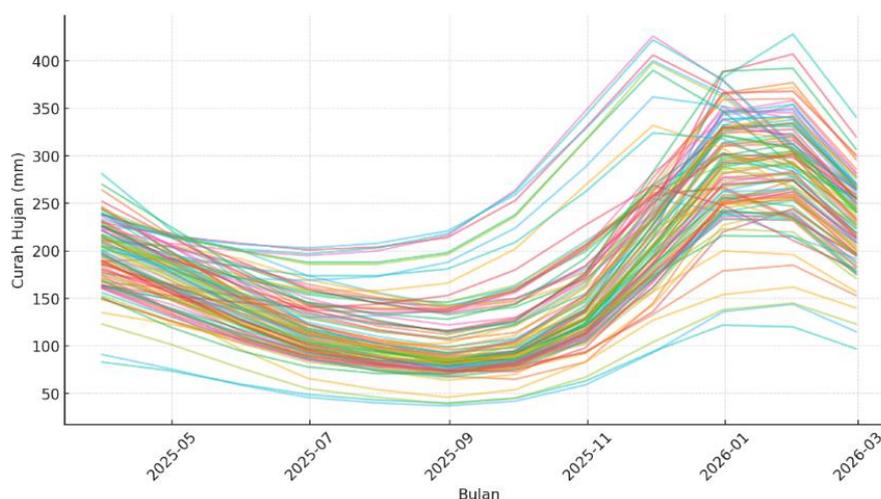
3. HASIL DAN PEMBAHASAN

Penelitian ini diawali dengan tahap pengumpulan data curah hujan bulanan yang diperoleh dari BMKG atau instansi terkait. Data yang digunakan bersumber dari pengamatan pos hujan yang tersebar di Provinsi Lampung. Setelah data terkumpul, dilakukan tahap *preprocessing* yang mencakup konversi format tanggal (*datetime*), pengisian nilai hilang (NaN) menggunakan rata-rata kolom, serta normalisasi nilai dengan *MinMaxScaler* untuk menstandarkan rentang data. Langkah ini bertujuan agar model prediksi dapat mengolah data dengan lebih stabil dan menghindari bias akibat perbedaan skala antar variabel. Data yang telah diproses kemudian disusun dalam bentuk *sequence* dengan panjang 12 bulan sebagai input untuk memprediksi curah hujan pada bulan berikutnya. Dataset dibagi menjadi dua bagian, yaitu 80% data latih untuk membangun model dan 20% data uji untuk mengukur performa model terhadap data yang belum pernah dilihat sebelumnya. Pada tahap pemodelan, digunakan dua arsitektur *deep learning* utama, yaitu *Recurrent Neural Network* (RNN) dan *Gated Recurrent Unit* (GRU) atau alternatif *Bidirectional LSTM* (*BiLSTM*). Pemodelan dilakukan untuk mengidentifikasi metode yang paling efektif dalam memprediksi pola curah hujan bulanan di Lampung. Model dilatih menggunakan *optimizer* Adam dengan fungsi kerugian *Mean Squared Error* (MSE) selama sejumlah *epoch* yang telah ditentukan. Setelah pelatihan selesai, evaluasi kinerja dilakukan menggunakan tiga metrik utama: *Root Mean Squared Error* (RMSE) untuk mengukur rata-rata kesalahan dalam skala asli data, *Mean Absolute Error* (MAE) untuk menilai kesalahan absolut rata-rata, dan *R-squared* (R^2) untuk melihat kemampuan model dalam menjelaskan variasi data. Hasil evaluasi ini dianalisis untuk membandingkan keunggulan masing-masing model, yang selanjutnya digunakan sebagai dasar dalam penarikan kesimpulan dan pemberian rekomendasi.



3.1 Hasil

Berdasarkan hasil prediksi model RNN untuk periode Maret 2025 hingga Februari 2026, pola musiman curah hujan di Provinsi Lampung terlihat jelas dengan tren penurunan dari Maret hingga Agustus 2025 yang mengindikasikan musim kemarau, diikuti peningkatan signifikan dari September 2025 hingga puncaknya pada Desember 2025–Januari 2026 saat musim hujan. Pada awal periode, sebagian besar wilayah mencatat curah hujan di atas 200 mm, namun menurun hingga di bawah 150 mm pada Juni–Juli 2025 yang menunjukkan kondisi kering pertengahan tahun. Memasuki September, curah hujan meningkat kembali, dengan sebagian besar wilayah mencatat lebih dari 200 mm pada puncak musim hujan, bahkan mencapai 270 mm di beberapa lokasi. Perbedaan distribusi hujan antarwilayah juga terlihat, di mana daerah dataran tinggi dan dekat pantai cenderung mencatat curah hujan lebih tinggi dibandingkan wilayah selatan dan tengah Lampung yang relatif kering. Selain pola umum tersebut, prediksi RNN mengidentifikasi potensi anomali, seperti curah hujan ekstrem pada Desember 2025 dan Januari 2026 yang di beberapa lokasi melebihi 300 mm, berpotensi meningkatkan risiko banjir, serta curah hujan sangat rendah pada Juni–Juli 2025 yang dapat mengindikasikan kekeringan ekstrem. Terdapat pula fluktuasi curah hujan tak terduga di beberapa pos, yang kemungkinan dipengaruhi faktor eksternal seperti anomali iklim global (ENSO, IOD) atau keterbatasan model dalam menangkap pola musiman secara konsisten. Oleh karena itu, hasil ini memerlukan validasi lanjutan terhadap data historis guna memastikan keakuratan prediksi, sekaligus menjadi bahan pertimbangan dalam penyesuaian parameter model agar hasil prediksi lebih stabil dan representatif terhadap kondisi atmosfer sebenarnya.

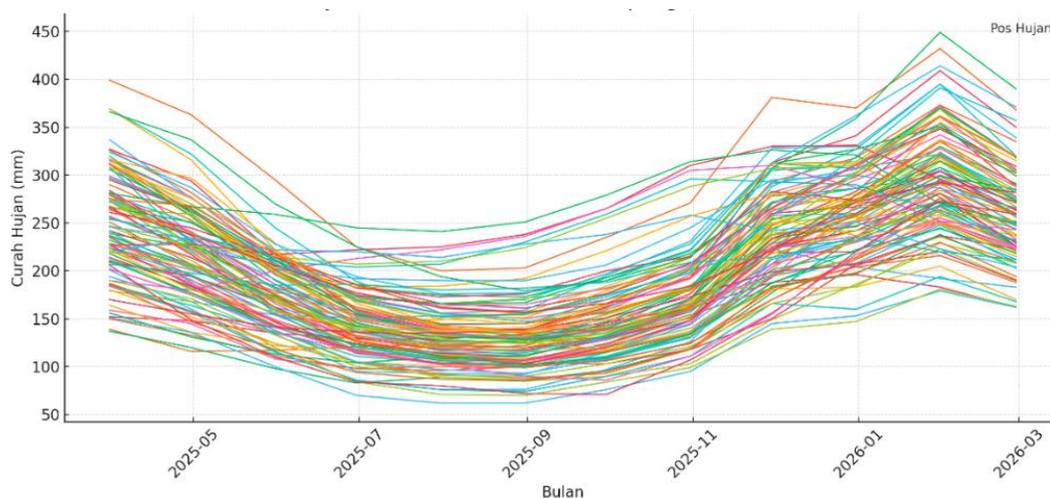


Gambar 2 Prediksi Curah Hujan Bulanan RNN Provinsi Lampung (Maret 2025 – Februari 2026)

Berdasarkan Gambar 2, pola curah hujan di wilayah ini menunjukkan variasi yang mencerminkan dinamika musim hujan dan kemarau. Secara umum, curah hujan bulanan cenderung menurun pada pertengahan tahun sebelum kembali meningkat menjelang akhir tahun. Penurunan ini menandakan peralihan menuju musim kemarau, sementara kenaikan yang signifikan mengindikasikan awal dan puncak musim hujan. Beberapa wilayah pos hujan menunjukkan fluktuasi yang lebih tajam dibandingkan wilayah lainnya, yang dapat disebabkan oleh faktor lokal seperti topografi dan pola angin musiman. Dari hasil prediksi, wilayah Lampung diperkirakan akan mengalami puncak musim kemarau pada bulan Agustus 2025, ditandai dengan curah hujan yang mencapai titik terendah di sebagian besar pos hujan. Penurunan curah hujan yang cukup signifikan mulai terlihat sejak bulan Juni hingga Agustus 2025, yang merupakan karakteristik umum musim kemarau di wilayah ini. Dalam periode ini, potensi kekeringan dan kebakaran hutan serta lahan perlu diantisipasi, terutama di daerah yang rawan terhadap kekeringan. Selain itu, sektor pertanian yang bergantung pada curah hujan juga harus bersiap menghadapi berkurangnya pasokan air. Sebaliknya, puncak musim hujan diperkirakan terjadi pada bulan Januari 2026, di mana curah hujan mencapai angka tertinggi secara keseluruhan. Kenaikan curah hujan mulai terlihat sejak Oktober 2025, mengindikasikan awal musim hujan. Peningkatan curah hujan yang signifikan ini dapat meningkatkan risiko bencana hidrometeorologi seperti banjir dan tanah longsor, terutama di daerah dataran rendah dan perkubitan. Oleh karena itu, langkah-langkah mitigasi seperti pemantauan intensif terhadap daerah rawan banjir, perbaikan sistem drainase, serta kesiapsiagaan dalam distribusi bantuan dan evakuasi perlu disiapkan sejak dini.

Hasil prediksi curah hujan menggunakan model GRU untuk periode Maret 2025 hingga Februari 2026 menunjukkan variasi antar bulan dan wilayah di Provinsi Lampung. Pada Maret hingga Mei 2025, sebagian besar pos hujan masih mencatat curah hujan tinggi, menandakan fase transisi dari musim hujan menuju musim kemarau. Tren penurunan mulai terlihat konsisten sejak Juni hingga mencapai titik terendah pada Agustus 2025, yang merupakan periode puncak musim kemarau di wilayah ini. Meskipun demikian, beberapa pos hujan masih mencatat fluktuasi curah hujan yang kemungkinan dipengaruhi oleh faktor lokal seperti orografi atau dinamika atmosfer setempat. Setelah Agustus, pola curah hujan menunjukkan peningkatan bertahap pada September dan Oktober 2025, kemudian naik signifikan mulai November hingga mencapai puncak pada Januari 2026, yang menjadi periode musim hujan paling intens dengan curah hujan tertinggi dalam setahun. Februari 2026 masih menunjukkan curah hujan kategori tinggi meskipun sedikit menurun

dibanding Januari. Analisis *Interquartile Range* (IQR) mengonfirmasi bahwa prediksi GRU berada dalam rentang normal tanpa adanya anomali signifikan, menunjukkan hasil yang stabil dan bebas dari lonjakan ekstrem atau penurunan drastis yang dapat dianggap sebagai *outlier*.



Gambar 3 Prediksi Curah Hujan Bulanan GRU Provinsi Lampung (Maret 2025 – Februari 2026)

Berdasarkan Gambar 3, musim kemarau di wilayah Lampung diperkirakan berlangsung dari Juni hingga September 2025, dengan puncak musim kemarau terjadi pada Agustus 2025. Pada bulan ini, sebagian besar wilayah mengalami curah hujan yang sangat rendah, sehingga wilayah-wilayah yang bergantung pada curah hujan untuk sektor pertanian dan sumber air bersih perlu mewaspadaai kemungkinan dampak dari musim kemarau yang panjang. Sebaliknya, musim hujan diprediksi mulai kembali menguat pada bulan Oktober 2025, dengan curah hujan yang terus meningkat hingga mencapai puncaknya pada Januari 2026. Bulan ini menjadi periode dengan curah hujan tertinggi dalam satu tahun ke depan, yang berpotensi menyebabkan banjir di beberapa daerah yang rentan terhadap genangan air dan aliran sungai yang meluap. Pola ini cukup konsisten dengan tren klimatologi wilayah Lampung, di mana musim hujan biasanya berlangsung dari akhir tahun hingga awal tahun berikutnya. Meskipun demikian, beberapa wilayah menunjukkan sedikit perbedaan dalam waktu puncak hujan atau kemarau, yang dapat disebabkan oleh faktor lokal seperti kondisi topografi, perbedaan ketinggian, atau pengaruh dinamika atmosfer lainnya. Oleh karena itu, dalam memahami tren curah hujan ini, penting untuk tidak hanya melihat pola umum, tetapi juga mempertimbangkan faktor-faktor lokal yang dapat menyebabkan variasi antar wilayah. Prediksi curah hujan ini memiliki implikasi penting bagi perencanaan mitigasi bencana hidrometeorologi di Provinsi Lampung. Dengan teridentifikasinya periode puncak musim kemarau pada Agustus 2025, perlu dilakukan langkah-langkah mitigasi yang mencakup pengelolaan sumber daya air secara efisien untuk mencegah kekeringan di sektor pertanian dan pemenuhan kebutuhan air bersih bagi masyarakat. Selain itu, pemantauan terhadap hotspot kebakaran hutan dan lahan perlu ditingkatkan, mengingat rendahnya curah hujan pada bulan-bulan tersebut dapat meningkatkan risiko kebakaran lahan gambut atau kawasan hutan di Lampung. Langkah preventif seperti patroli rutin, peningkatan kesadaran masyarakat, serta penyediaan sarana pemadaman dini menjadi langkah yang perlu dioptimalkan dalam periode ini.

Di sisi lain, dengan adanya puncak musim hujan pada Januari 2026, risiko bencana hidrometeorologi yang berpotensi terjadi adalah banjir dan tanah longsor. Oleh karena itu, perlu dilakukan pemantauan yang lebih intensif terhadap wilayah-wilayah yang rentan terhadap genangan air dan banjir bandang, terutama di sekitar daerah aliran sungai dan daerah dataran rendah. Peningkatan kapasitas drainase, penguatan tanggul sungai, serta sosialisasi kepada masyarakat terkait langkah-langkah mitigasi banjir menjadi hal yang sangat penting untuk dilakukan sebelum memasuki puncak musim hujan. Selain itu, daerah yang memiliki topografi berbukit dan rawan tanah longsor perlu mendapatkan perhatian lebih, terutama dalam hal pemantauan kondisi tanah dan penerapan sistem peringatan dini terhadap potensi longsor. Hasil prediksi hujan bulanan GRU juga dapat digunakan oleh berbagai sektor, termasuk pertanian, perikanan, dan transportasi, untuk menyesuaikan strategi operasional mereka berdasarkan pola curah hujan yang diharapkan. Sebagai contoh, sektor pertanian dapat menggunakan informasi ini untuk menentukan pola tanam yang lebih sesuai dengan musim hujan dan kemarau yang akan datang, sehingga dapat mengurangi risiko gagal panen akibat kondisi cuaca yang ekstrem. Sementara itu, sektor transportasi dan infrastruktur perlu mempertimbangkan peningkatan frekuensi curah hujan yang tinggi pada akhir tahun dan awal tahun berikutnya, yang dapat berdampak pada kondisi jalan dan kemungkinan terjadinya longsor di jalur-jalur tertentu.

Evaluasi performa model prediksi hujan bulanan di Provinsi Lampung dilakukan dengan membandingkan dua arsitektur jaringan saraf tiruan, yaitu Recurrent Neural Network (RNN) dan Gated Recurrent Unit (GRU), menggunakan tiga metrik evaluasi utama: Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan R-squared (R^2). Berdasarkan Tabel 2, hasil evaluasi menunjukkan bahwa RNN memiliki performa yang lebih baik dibandingkan GRU pada seluruh metrik. RNN mencatat RMSE sebesar 115,61, lebih rendah dibandingkan GRU dengan 119,50, yang berarti kesalahan prediksi RNN lebih kecil. Dalam hal MAE, RNN juga unggul dengan 86,94 dibandingkan GRU yang mencapai



91,28, menandakan prediksi RNN lebih mendekati nilai aktual. Selain itu, nilai R^2 RNN sebesar 0,35 lebih tinggi dibandingkan GRU sebesar 0,30, menunjukkan kemampuan RNN yang lebih baik dalam menjelaskan variasi data curah hujan bulanan. Keunggulan RNN ini dapat dikaitkan dengan kemampuannya mempertahankan informasi jangka panjang secara lebih efektif, sehingga mampu menangkap pola temporal yang kompleks dalam data curah hujan. Sementara itu, meskipun GRU memiliki struktur yang lebih sederhana dan proses pelatihan lebih cepat, penyederhanaan tersebut berdampak pada penurunan akurasi dalam memodelkan data dengan variabilitas tinggi. Namun, nilai R^2 kedua model yang masih di bawah 0,5 mengindikasikan bahwa keduanya belum optimal dalam menjelaskan variabilitas curah hujan bulanan. Beberapa faktor yang kemungkinan belum sepenuhnya ditangkap oleh model meliputi variabel atmosfer lain seperti suhu, kelembapan, tekanan udara, serta fenomena iklim global seperti ENSO dan IOD. Berdasarkan temuan ini, RNN dinilai lebih layak digunakan dibandingkan GRU untuk prediksi curah hujan bulanan di Provinsi Lampung, meskipun masih terdapat ruang perbaikan signifikan. Upaya peningkatan dapat dilakukan dengan menambahkan fitur meteorologi tambahan, memperluas jumlah data historis, melakukan tuning hiperparameter, atau mengadopsi arsitektur hybrid seperti RNN dengan Attention Mechanism atau Transformer. Selain itu, penerapan teknik regularisasi yang lebih efektif dapat membantu mengurangi overfitting dan meningkatkan generalisasi model. Dengan optimalisasi lebih lanjut, diharapkan model dapat memberikan prediksi yang lebih presisi dan handal, sehingga mampu mendukung pengambilan keputusan terkait mitigasi bencana hidrometeorologi dan perencanaan sumber daya air secara lebih efektif.

Tabel 2 Evaluasi Model RNN dan GRU

Evaluasi Model	RNN	GRU
RMSE	115.61	119.5
MAE	86.94	91.28
R^2 Score	0.35	0.3

3.2 Pembahasan

Hasil prediksi curah hujan bulanan menggunakan model RNN dan GRU menunjukkan bahwa pola curah hujan di Provinsi Lampung masih mengikuti siklus musiman yang konsisten dengan tren klimatologis wilayah ini, yaitu musim kemarau yang umumnya terjadi pada pertengahan tahun (Juni–Agustus) dan musim hujan yang berlangsung dari akhir hingga awal tahun berikutnya (Oktober–Februari). RNN mampu menangkap fluktuasi curah hujan yang lebih detail, termasuk anomali ekstrem seperti curah hujan yang melebihi 300 mm pada Desember 2025 dan Januari 2026, yang mengindikasikan potensi risiko banjir signifikan. Sementara itu, GRU memberikan prediksi yang lebih stabil tanpa lonjakan ekstrem, sehingga dapat mengurangi risiko false alarm dalam sistem peringatan dini. Perbedaan ini mengindikasikan bahwa meskipun RNN memiliki sensitivitas yang tinggi terhadap variasi data, GRU lebih unggul dalam menjaga kestabilan prediksi jangka panjang. Dari sisi implikasi praktis, hasil prediksi ini memberikan gambaran penting bagi sektor-sektor strategis di Lampung, terutama pertanian, pengelolaan sumber daya air, dan mitigasi bencana hidrometeorologi. Prediksi penurunan curah hujan pada Juni–Agustus 2025 menunjukkan perlunya perencanaan distribusi air yang efisien untuk mencegah kekeringan dan mengantisipasi risiko kebakaran hutan/lahan. Sebaliknya, puncak curah hujan pada Desember 2025–Januari 2026 memerlukan strategi pengelolaan banjir seperti peningkatan kapasitas drainase, penguatan tanggul, dan pemantauan daerah aliran sungai. Selain itu, perbedaan distribusi curah hujan antarwilayah, yang dipengaruhi oleh faktor topografi dan kedekatan dengan sumber uap air, menekankan pentingnya penerapan strategi mitigasi yang berbasis pada kondisi lokal, bukan hanya pada tren umum provinsi.

Evaluasi performa model menunjukkan bahwa RNN memiliki nilai RMSE, MAE, dan R^2 yang lebih baik dibandingkan GRU, sehingga lebih akurat dalam merepresentasikan pola curah hujan musiman dan anomali. Dibandingkan dengan penelitian sebelumnya yang menggunakan model *machine learning* tradisional seperti Random Forest atau Support Vector Regression (SVR), hasil penelitian ini menunjukkan peningkatan akurasi yang signifikan. Peningkatan ini terlihat dari penurunan nilai RMSE dan MAE, serta kenaikan nilai R^2 yang mengindikasikan kemampuan model dalam menjelaskan variasi data lebih baik. Hal ini membuktikan bahwa penerapan arsitektur *deep learning* berbasis RNN dan GRU mampu mengakomodasi karakteristik data deret waktu yang kompleks, sehingga memberikan hasil prediksi yang lebih presisi. Meskipun demikian, nilai R^2 yang masih di bawah 0,5 pada kedua model menunjukkan bahwa variabilitas curah hujan belum sepenuhnya ter jelaskan. Oleh karena itu, peningkatan akurasi di masa mendatang dapat dilakukan melalui integrasi variabel meteorologis tambahan seperti suhu, kelembapan, tekanan udara, serta indeks iklim global (ENSO, IOD), penambahan jumlah data historis, dan penerapan arsitektur hybrid seperti RNN-Transformer dengan mekanisme attention. Dengan langkah ini, model diharapkan mampu memberikan prediksi yang lebih akurat sekaligus memperkuat sistem peringatan dini bencana hidrometeorologi.

4. KESIMPULAN

Penelitian ini bertujuan untuk membandingkan performa *Recurrent Neural Network* (RNN) dan *Gated Recurrent Unit* (GRU) dalam memprediksi curah hujan bulanan di Provinsi Lampung. Dengan menggunakan dataset curah hujan bulanan dari 80 pos hujan yang tersebar di 15 kabupaten/kota untuk periode Januari 1991 – Februari 2025, kedua model *deep learning* dikembangkan dan dievaluasi berdasarkan tiga metrik, yaitu *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan koefisien determinasi (R^2). Hasil penelitian menunjukkan bahwa model RNN memiliki performa lebih



baik dibandingkan GRU, dengan nilai RMSE yang lebih rendah (115,61 vs. 119,50), MAE yang lebih kecil (86,94 vs. 91,28), serta R^2 yang lebih tinggi (0,35 vs. 0,30). Keunggulan RNN dibandingkan GRU dalam penelitian ini disebabkan oleh kemampuannya mempertahankan informasi jangka panjang secara lebih efektif pada data curah hujan bulanan yang memiliki pola musiman dan tren jangka panjang yang kuat. Struktur RNN yang digunakan terbukti mampu menangkap kompleksitas pola temporal serta variasi antarbulan dengan lebih detail, sehingga mampu memodelkan peralihan musim kemarau ke musim hujan dan sebaliknya dengan tingkat kesalahan prediksi yang lebih rendah. Sementara itu, meskipun GRU memiliki arsitektur yang lebih sederhana dan proses pelatihan yang lebih cepat, penyederhanaan mekanisme *gating*-nya membuat model ini cenderung kurang sensitif dalam menangkap variasi musiman yang kompleks di wilayah Lampung. Pola prediksi yang dihasilkan RNN sesuai dengan tren klimatologi di Provinsi Lampung, di mana puncak musim kemarau diprediksi terjadi pada Agustus 2025 dan puncak musim hujan pada Januari 2026. Meskipun demikian, nilai R^2 yang masih di bawah 0,5 menunjukkan bahwa kedua model belum sepenuhnya optimal dalam menjelaskan variabilitas curah hujan, yang kemungkinan dipengaruhi oleh faktor eksternal seperti ENSO, IOD, dan dinamika atmosfer lainnya. Untuk meningkatkan akurasi, langkah pengembangan yang direkomendasikan meliputi penambahan variabel meteorologi tambahan (kelembapan, suhu, tekanan udara), penggunaan arsitektur hybrid seperti RNN dengan mekanisme Attention, serta tuning hiperparameter lebih lanjut. Dengan hasil ini, penelitian diharapkan dapat menjadi dasar pengambilan keputusan dalam pengelolaan sumber daya air, mitigasi bencana hidrometeorologi, serta perencanaan sektor pertanian dan infrastruktur di Provinsi Lampung. Model prediksi yang lebih akurat akan mendukung kesiapsiagaan terhadap variabilitas cuaca dan iklim di wilayah ini.

REFERENCES

- [1] L. Latifoğlu, "A novel combined model for prediction of daily precipitation data using instantaneous frequency feature and bidirectional long short time memory networks," *Environ. Sci. Pollut. Res.*, vol. 29, no. 28, pp. 42899–42912, 2022, doi: 10.1007/s11356-022-18874-z.
- [2] M. Saleem, M. M. Saleem, F. Waseem, and M. A. Bashir, "An Ensemble Forecasting Method based on optimized LSTM and GRU for Temperature and Humidity Forecasting," *Eng. Technol. Appl. Sci. Res.*, vol. 14, no. 6, pp. 18447–18452, 2024, doi: 10.48084/etasr.9047.
- [3] M. D. A. Carnegie and C. Chairani, "Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Memprediksi Curah Hujan," *J. Media Inform. Budidarma*, vol. 7, no. 3, p. 1022, 2023, doi: 10.30865/mib.v7i3.6213.
- [4] W. Surta, K. T. Basuki, E. S. Negara, and Y. N. Kunang, "Rainfall prediction in Palembang City using the GRU and LSTM methods," *Journal of Data Science*, vol. 4, no. 2, pp. 1–10, 2023. [Online]. Available: <http://eprints.intimal.edu.my/1730/>
- [5] A. Radford *et al.*, "Learning transferable visual models from natural language supervision," in *Proceedings of the 38th International Conference on Machine Learning (ICML)*, vol. 139, 2021, pp. 8748–8763. doi: 10.48550/arXiv.2103.00020.
- [6] A. Falcon, G. D'Agostino, O. Lanz, G. Brajnik, C. Tasso, and G. Serra, "Neural Turing Machines for the Remaining Useful Life estimation problem," *Comput. Ind.*, vol. 143, p. 103762, Dec. 2022, doi: 10.1016/J.COMPIND.2022.103762.
- [7] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [8] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
- [9] A. Radford *et al.*, "Learning transferable visual models from natural language supervision," in *Proceedings of the 38th International Conference on Machine Learning (ICML)*, vol. 139, 2021, pp. 8748–8763. doi: 10.48550/arXiv.2103.00020.
- [10] Y. Bengio, P. Y. Simard, and I. Larochelle, "Learning Long-Term Dependencies with Gradient Descent is Difficult," *IEEE Trans. Neural Networks*, vol. 5, no. November, pp. 157–166, 1994, doi: 10.1109/72.279181.
- [11] F. Zhang, "Weather forecasting and analysis with LSTM based on deep learning," in *Proceedings of the 2019 2nd International Conference on Information, Computing and Artificial Intelligence (ICIAI)*, Atlantis Press, 2019, pp. 1–5, doi: 10.2991/iciai-19.2019.1. [12] J. Chung, "Gated Recurrent Neural Networks on Sequence Modeling arXiv : 1412 . 3555v1 [cs . NE] 11 Dec 2014," *NIPS 2014 Work. Deep Learn.*, pp. 1–9, 2014.
- [13] S. Hemamalini, G. R. K. B. Rajasekar, and S. S. M., "An intelligent weather prediction model using optimized 1D CNN with attention GRU," *Journal of Intelligent & Fuzzy Systems*, vol. 26, no. 2, pp. 1–9, 2024. doi: 10.3233/JIFS-232345.
- [14] C. Ni, M. F. Marsani, F. P. Shan, and X. Zou, "Flood prediction with optimized gated recurrent unit-temporal convolutional network and improved KDE error estimation," vol. 9, no. January, pp. 14681–14696, 2024, doi: 10.3934/math.2024714.
- [15] I. Firmansyah, A. Yulianto, dan R. Andrian, "Prediksi Curah Hujan Bulanan Menggunakan Metode Long Short-Term Memory (LSTM) di Provinsi Lampung," *Jurnal Teknologi Informasi dan Komunikasi*, vol. 11, no. 2, pp. 122–130, 2023.
- [16] N. S. Lestari dan M. D. Pratama, "Implementasi Algoritma Gated Recurrent Unit (GRU) pada Prediksi Iklim di Sumatera Bagian Selatan," *Explore: Jurnal Sistem Informasi dan Telematika*, vol. 14, no. 1, pp. 33–41, 2023.
- [17] R. Nugroho, D. Anggraini, dan T. S. Putra, "Pemanfaatan Deep Learning untuk Analisis Data Hidrometeorologi di Lampung," *Jurnal Sistem Cerdas*, vol. 8, no. 2, pp. 88–96, 2022.
- [18] A. P. Santoso dan S. Chairani, "Perbandingan Model RNN dan LSTM dalam Prediksi Cuaca Jangka Panjang," *Jurnal Ilmu Komputer Darmajaya*, vol. 9, no. 1, pp. 45–54, 2022.
- [19] Y. F. Maulana, A. Pratiwi, dan I. Cahyono, "Optimasi Prediksi Curah Hujan Menggunakan Deep Neural Network dengan Regularisasi Dropout," *Prosiding Seminar Nasional Ilmu Komputer Darmajaya*, pp. 210–217, 2023.
- [20] H. Kurniawan dan R. Saputra, "Evaluasi Performansi Metode Machine Learning untuk Prediksi Cuaca di Provinsi Lampung," *Jurnal Informatika Darmajaya*, vol. 15, no. 2, pp. 99–107, 2022.