



Prediksi Cuaca Harian Menggunakan Algoritma Long Short-Term Memory (LSTM) Berdasarkan Data Meteorologi Tahun 2025

Ika Novianti*, Fathir, Irma Eryanti Putri

Fakultas Teknik dan Ilmu Komputer, Ilmu Komputer, Universitas Muhammadiyah Bima, Bima
Jl. Angrek No. 16 Ranggo, Nae, Kec. Rasanae Barat, Kab. Bima, Nusa Tenggara Barat, Indonesia

Email: ^{1,*}noviantiika789@gmail.com, ²fathirpuncak@gmail.com, ³irerput1802@gmail.com

Email Penulis Korespondensi: noviantiika789@gmail.com

Submitted: 09/07/2026; Accepted: 30/07/2026; Published: 30/07/2026

Abstrak—Prediksi cuaca harian merupakan hal penting dalam mendukung pengambilan keputusan di sektor pertanian, transportasi, mitigasi bencana, serta kegiatan masyarakat yang dipengaruhi oleh kondisi atmosfer. Cuaca di Kota Bima memiliki karakteristik yang dinamis, sehingga diperlukan model prediksi yang mampu belajar pola data meteorologi secara berurutan. Penelitian ini bertujuan untuk membangun model prediksi suhu rata-rata harian menggunakan algoritma Long Short-Term Memory (LSTM) berdasarkan data meteorologis tahun 2025. Kontribusi penelitian ini adalah mengembangkan model prediksi suhu rata-rata harian berbasis LSTM menggunakan data meteorologi multivariat Kota Bima yang dikombinasikan dengan tahapan prapemrosesan berupa penanganan missing value menggunakan moving average, normalisasi MinMaxScaler, dan pembentukan data time series menggunakan sliding window 30 hari. Penelitian ini juga memberikan evaluasi awal terhadap penerapan LSTM pada data meteorologi lokal Kota Bima yang masih terbatas dikaji sebagai dasar pengembangan sistem prediksi cuaca berbasis deep learning. Variabel yang digunakan meliputi suhu minimum (TN), suhu maksimum (TX), suhu rata-rata (TAVG), kelembapan udara rata-rata (RH_AVG), curah hujan (RR), durasi penyinaran matahari (SS), dan kecepatan angin rata-rata (FF_AVG). Hasil pengujian menunjukkan bahwa model menghasilkan nilai Root Mean Square Error (RMSE) sebesar 0,7242 dan mampu mengikuti pola perubahan suhu harian pada data aktual. Hasil prediksi pada data pengujian juga menunjukkan bahwa sebagian besar nilai prediksi memiliki selisih yang relatif kecil dibandingkan dengan nilai aktual, sehingga model mampu menggambarkan pola perubahan suhu harian dengan cukup baik. Berdasarkan parameter cuaca yang diprediksi, model mampu memberikan informasi mengenai kondisi cuaca harian, yaitu cerah, mendung, dan hujan, sesuai dengan nilai curah hujan, kelembapan udara, dan lama penyinaran matahari yang dihasilkan. Informasi prediksi tersebut diharapkan dapat membantu masyarakat sebagai gambaran awal kondisi cuaca yang akan terjadi sehingga dapat mendukung perencanaan berbagai aktivitas sehari-hari. Meskipun demikian, hasil penelitian ini masih terbatas pada satu metode prediksi dan belum dibandingkan dengan metode lain. Oleh karena itu, penelitian selanjutnya dapat melakukan perbandingan dengan algoritma lain untuk meningkatkan akurasi prediksi cuaca di Kota Bima.

Kata Kunci: Prediksi Cuaca; Long Short-Term Memory (LSTM); Suhu Rata-Rata Harian; Time Series; Deep Learning; RMSE.

Abstract—Daily weather prediction is crucial in supporting decision-making in the agriculture, transportation, disaster mitigation, and community activities influenced by atmospheric conditions. The weather in Bima City is dynamic, requiring a predictive model capable of learning sequential meteorological data patterns. This study aims to build a daily average temperature prediction model using the Long Short-Term Memory (LSTM) algorithm based on 2025 meteorological data. The contribution of this study is to develop an LSTM-based daily average temperature prediction model using multivariate meteorological data from Bima City combined with pre-processing steps in the form of missing value handling using moving averages, MinMaxScaler normalization, and time series data formation using a 30-day sliding window. This study also provides an initial evaluation of the application of LSTM to local meteorological data from Bima City, which has been studied only limitedly, as a basis for developing a deep learning-based weather prediction system. The variables used include minimum temperature (TN), maximum temperature (TX), average temperature (TAVG), average air humidity (RH_AVG), rainfall (RR), sunshine duration (SS), and average wind speed (FF_AVG). The test results show that the model produces a Root Mean Square Error (RMSE) value of 0.7242 and is able to follow the daily temperature change pattern in the actual data. The prediction results on the test data also show that most of the predicted values have a relatively small difference compared to the actual values, so the model is able to describe the daily temperature change pattern quite well. Based on the predicted weather parameters, the model is able to provide information about daily weather conditions, namely sunny, cloudy, and rainy, according to the values of rainfall, air humidity, and sunshine duration produced. This predicted information is expected to help the community as an initial picture of future weather conditions so that it can support the planning of various daily activities. However, the results of this study are still limited to one prediction method and have not been compared with other methods. Therefore, further research can conduct comparisons with other algorithms to improve the accuracy of weather predictions in Bima City.

Keywords: Weather Prediction; Long Short-Term Memory (LSTM); Daily Average Temperature; Time Series; Deep Learning; RMSE

1. PENDAHULUAN

Cuaca merupakan salah satu faktor yang memengaruhi berbagai aktivitas masyarakat, seperti pertanian, transportasi, perikanan, hingga mitigasi bencana. Informasi prakiraan cuaca yang akurat sangat dibutuhkan untuk mendukung pengambilan keputusan serta mengurangi risiko kerugian akibat kondisi cuaca ekstrem [1]. Seiring dengan perkembangan teknologi, metode prediksi cuaca terus mengalami kemajuan melalui pemanfaatan data historis dan teknik kecerdasan buatan. Prediksi cuaca bertujuan memahami perubahan kondisi atmosfer dari waktu

ke waktu sehingga dapat memberikan informasi mengenai kondisi cuaca pada masa yang akan datang sebagai langkah antisipasi terhadap perubahan cuaca yang tidak menentu [2].

Prediksi cuaca termasuk ke dalam permasalahan time series, yaitu data yang memiliki ketergantungan antarwaktu dan dipengaruhi oleh hubungan yang kompleks antarameteorologi, seperti suhu, kelembapan udara, curah hujan, lama penyinaran matahari, serta kecepatan angin[3]. Karakteristik tersebut menyebabkan metode statistik konvensional memiliki keterbatasan dalam memodelkan pola nonlinier, sehingga pendekatan berbasis deep learning semakin banyak diterapkan untuk meningkatkan akurasi prediksi [4].

Salah satu metode deep learning yang banyak digunakan pada data time series adalah Long Short-Term Memory (LSTM)[5]. LSTM merupakan pengembangan dari Recurrent Neural Network (RNN) yang dirancang untuk mengatasi permasalahan vanishing gradient, sehingga mampu mempelajari ketergantungan jangka pendek maupun jangka panjang pada data sekuensial[6]. Arsitektur LSTM menggunakan mekanisme gate yang mengatur informasi yang dipertahankan maupun dihilangkan selama proses pelatihan sehingga lebih efektif dalam memodelkan pola historis dibandingkan RNN konvensional[7]. Selain itu, kemampuan LSTM dalam mengolah data multivariat menjadikannya sesuai untuk prediksi cuaca yang dipengaruhi oleh beberapa parameter meteorologi secara bersamaan [8].

Berbagai penelitian terdahulu menunjukkan bahwa LSTM memberikan hasil yang baik pada prediksi parameter cuaca maupun bidang lainnya. LSTM telah diterapkan untuk memprediksi suhu cuaca di Norwegia, curah hujan di Kota Bandung, serta berbagai kasus prediksi deret waktu lainnya dengan tingkat akurasi yang baik dan nilai kesalahan prediksi yang relatif rendah [4], [9], [10]. Namun, sebagian besar penelitian tersebut hanya berfokus pada evaluasi performa model di wilayah tertentu atau membandingkan pengaruh parameter pelatihan, seperti jumlah epoch, batch size, maupun komposisi data latih dan data uji. Selain itu, karakteristik meteorologi setiap wilayah berbeda sehingga model yang dikembangkan pada daerah lain belum tentu memberikan performa yang sama ketika diterapkan pada data cuaca Kota Bima. Dengan demikian, masih terdapat kesenjangan penelitian (research gap) berupa terbatasnya kajian penerapan LSTM pada data meteorologi Kota Bima dengan memanfaatkan beberapa parameter cuaca sebagai variabel masukan untuk memprediksi suhu rata-rata harian. Berbeda dengan penelitian-penelitian tersebut, penelitian ini berfokus pada wilayah Kota Bima yang memiliki karakteristik iklim berbeda dan relatif belum banyak dikaji menggunakan pendekatan prediksi cuaca yang lebih menyeluruh dengan melibatkan beberapa parameter cuaca secara multivariat, serta menitikberatkan pada analisis proses prapemrosesan, pelatihan, pengujian, dan evaluasi model LSTM secara sistematis, sehingga diharapkan mampu memberikan kontribusi ilmiah baru sekaligus manfaat praktis yang kontekstual bagi kebutuhan mitigasi bencana, sektor pertanian, dan perencanaan aktivitas masyarakat di wilayah Bima.

Dalam beberapa tahun terakhir telah berkembang arsitektur yang lebih modern, seperti Transformer maupun model hybrid deep learning[11]. Akan tetapi, metode tersebut umumnya membutuhkan jumlah data pelatihan yang lebih besar, kompleksitas komputasi yang lebih tinggi, serta proses pelatihan yang lebih lama dibandingkan LSTM. Mengingat penelitian ini menggunakan dataset meteorologi harian Kota Bima dengan jumlah data yang relatif terbatas, LSTM dipilih karena masih mampu memodelkan hubungan temporal secara efektif dengan kebutuhan komputasi yang lebih efisien serta telah banyak digunakan sebagai metode acuan pada penelitian prediksi cuaca berbasis time series [12].

Berdasarkan kondisi tersebut, penelitian ini bertujuan membangun model prediksi suhu rata-rata harian di Kota Bima menggunakan algoritma Long Short-Term Memory (LSTM) berdasarkan data meteorologi tahun 2025. Tahapan penelitian meliputi prapemrosesan data menggunakan moving average untuk menangani missing value, normalisasi menggunakan MinMaxScaler, pembentukan data deret waktu dengan teknik sliding window berukuran 30 hari, serta pelatihan model LSTM untuk memprediksi suhu rata-rata harian[13]. Penelitian ini diharapkan dapat memberikan gambaran mengenai kemampuan LSTM dalam memodelkan pola cuaca harian di Kota Bima serta menjadi dasar bagi penelitian selanjutnya yang membandingkan performa LSTM dengan arsitektur deep learning yang lebih modern, seperti Transformer maupun model hibrida[14].

Kontribusi utama penelitian ini terletak pada penerapan model Long Short-Term Memory (LSTM) untuk memprediksi suhu rata-rata harian menggunakan data meteorologi multivariat Kota Bima yang masih relatif jarang diteliti. Selain itu, penelitian ini menyusun alur prapemrosesan data yang sistematis, meliputi penanganan missing value, normalisasi data, dan pembentukan data time series menggunakan sliding window 30 hari, sehingga dapat menjadi acuan dalam pengembangan model prediksi cuaca berbasis deep learning pada wilayah dengan karakteristik iklim yang serupa.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan data cuaca harian Kota Bima tahun 2025 yang didapat dari Stasiun Meteorologi Sultan Muhammad Salahuddin BMKG. Dataset ini berisi 380 pengamatan harian yang mencakup beberapa variabel seperti suhu terendah (TN), suhu tertinggi (TX), suhu rata-rata (TAVG), kelembapan udara rata-rata (RH_AVG), curah hujan (RR), lama penyinaran matahari (SS), kecepatan angin tertinggi (FF_X), arah angin saat kecepatan angin tertinggi (DDD_X), kecepatan angin rata-rata (FF_AVG), dan arah angin yang paling dominan (DDD_CAR). Semua data memiliki pengamatan setiap hari, sehingga setiap parameter sudah disinkronkan

berdasarkan tanggal observasi yang sama dan bisa digunakan sebagai data multivariat dalam proses pembelajaran model. Penelitian ini dilakukan melalui beberapa tahapan yang disusun secara terstruktur, mulai dari proses pengumpulan dan pra-pemrosesan data time series hingga penerapan sistem prediksi menggunakan algoritma Long Short-Term Memory (LSTM). Alur penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

Gambar 1 menunjukkan proses penelitian dimulai dengan mengumpulkan data cuaca harian, lalu data tersebut diproses terlebih dahulu agar bisa digunakan. Selanjutnya dilakukan pembuatan dan pelatihan model LSTM untuk belajar dari pola-pola suhu yang terjadi sebelumnya. Model yang sudah dilatih kemudian diuji dengan data uji dan dinilai menggunakan RMSE serta grafik yang membandingkan hasil aktual dan hasil prediksi. Hasil evaluasi tersebut dianalisis agar bisa mengetahui seberapa tepat model dalam memprediksi suhu rata-rata harian. Jika nilai RMSE kecil dan grafik hasil prediksi menyerupai pola data nyata, maka model LSTM dapat dikatakan bekerja dengan baik dalam memprediksi suhu rata-rata harian di Kota Bima.

2.1 Pengumpulan Data

Data penelitian terdiri dari data cuaca yang diperoleh dari Stasiun meteorologi Sultan Muhammad Salahudin Kota Bima. Data yang digunakan dalam penelitian ini mencakup data periode 2025 yang berjenis data time series yang meliputi kota Bima. Jumlah data yang sudah terkumpul yaitu sebanyak 350 yang mencakup variabel utama seperti variabel tanggal pengamatan (TANGGAL), suhu minimum (TN), suhu maksimum (TX), suhu rata-rata (TAVG), kelembapan rata-rata (RH_AVG), curah hujan (RR), lama penyinaran matahari (SS), kecepatan angin maksimum (FF_X), arah angin saat kecepatan maksimum (DDD_X), kecepatan angin rata-rata (FF_AVG), dan arah angin dominan (DDD_CAR). Dengan interval pengambilan data harian selama periode tertentu. Pengambilan data dilakukan secara konsisten untuk memastikan kualitas dan kelengkapan dataset. Data yang dikumpulkan memiliki beragam variasi, mencakup perubahan musim, tren jangka Panjang, dan fluktuasi harian yang berbeda [15].

2.2 Pra-pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk memastikan kualitas data sebelum digunakan dalam pelatihan model LSTM. Proses dimulai dengan pembersihan data, yaitu menghapus baris duplikat, mencari missing value dan memeriksa konsistensi format pada seluruh variabel cuaca. Selanjutnya, nilai data yang hilang ditangani menggunakan metode moving average agar kontinuitas deret waktu tetap terjaga dan tidak menimbulkan ketidakstabilan pada model [16]. Tahap pra-pemrosesan dilakukan untuk meningkatkan kualitas data sebelum digunakan pada model LSTM. Proses diawali dengan pemeriksaan data duplikat, identifikasi missing value, dan pengecekan konsistensi tipe data. Nilai yang hilang ditangani menggunakan metode moving average agar kontinuitas data time series tetap terjaga tanpa menghilangkan pola temporal. Setelah proses pembersihan selesai, seluruh variabel numerik dinormalisasi menggunakan metode MinMaxScaler sehingga setiap fitur berada pada rentang nilai 0–1. Normalisasi dilakukan karena setiap parameter meteorologi memiliki satuan dan rentang nilai yang berbeda, misalnya suhu menggunakan derajat Celcius (°C), curah hujan menggunakan milimeter (mm), kelembapan menggunakan persentase (%), serta lama penyinaran matahari menggunakan jam. Perbedaan skala tersebut dapat menyebabkan fitur dengan nilai terbesar mendominasi proses pembelajaran jaringan saraf. Oleh karena itu, MinMaxScaler digunakan untuk menyetarakan skala seluruh variabel sehingga setiap fitur memberikan kontribusi yang proporsional selama proses pelatihan model.

Selanjutnya data diubah menggunakan teknik jendela geser. Dalam penelitian ini, ukuran window digunakan sebesar 30 hari, artinya model menggunakan data cuaca selama 30 hari terakhir untuk memprediksi suhu rata-rata hari mendatang. Ukuran jendela yang dipilih didasarkan pada pertimbangan bahwa waktu satu bulan cukup mewakili pola temporal jangka pendek yang sering digunakan dalam memprediksi data cuaca harian. Selain itu, ukuran tersebut dipilih agar tetap seimbang antara jumlah data latih yang ada dan kemampuan model dalam memahami pola waktu. Penggunaan ukuran jendela dalam penelitian ini masih dilakukan secara empiris dan merupakan salah satu keterbatasan yang bisa diperbaiki dengan mencoba berbagai ukuran jendela dalam penelitian berikutnya. Dataset kemudian dipecah menjadi bagian data latih sebesar 80% dan bagian data uji sebesar 20%. Pembagian dilakukan secara berurutan sesuai dengan karakteristik data deret waktu sehingga urutan waktu data tetap terjaga dan tidak menyebabkan kebocoran informasi.

2.3 Perancangan dan Pelatihan Model LSTM

Model tersebut dibuat dengan menggunakan struktur Sequential yang terdiri dari satu lapisan LSTM dengan 64 neuron untuk mempelajari hubungan antar parameter cuaca secara temporal. Setelah lapisan LSTM, dilakukan lapisan Dropout sebagai cara untuk mengurangi kemungkinan model terlalu sempurna dalam mengenali data pelatihan. Selanjutnya ada lapisan Dense dengan 32 neuron yang berfungsi untuk ekstraksi fitur yang lebih lanjut, lalu satu neuron output digunakan untuk menghasilkan prediksi suhu rata-rata harian (TAVG). Model dilatih

dengan menggunakan fungsi loss Mean Squared Error (MSE) dan optimazer Adam selama 100 epoch[17]. Agar struktur arsitektur lebih mudah dipahami, penelitian ini menampilkan diagram model arsitektur yang menunjukkan alur data dari input berupa banyak variabel, melalui lapisan LSTM, Dropout, Dense, hingga hasil prediksi suhu rata-rata harian.

2.4 Pengujian dan Evaluasi Model

Tahap evaluasi model LSTM dilakukan dengan menggunakan metrik evaluasi yang sesuai dengan jenis permasalahan untuk kasus regresi atau peramalan deret waktu, metrik yang umum digunakan antara lain Root Mean Squared Error (RMSE). Root Mean Squared Error (RMSE) merupakan metrik evaluasi yang digunakan untuk mengukur tingkat kesalahan prediksi model Long Short-Term Memory (LSTM) dengan membandingkan nilai aktual dan nilai hasil prediksi pada data cuaca.

Dalam kasus memperkirakan cuaca di daerah Kota Bima, RMSE digunakan untuk mengetahui sejauh mana kemampuan model LSTM dalam memperkirakan nilai variabel cuaca berdasarkan data yang telah terjadi sebelumnya. Nilai RMSE yang rendah menunjukkan hasil prediksi model hampir mendekati nilai sebenarnya, artinya model tersebut memiliki kemampuan memprediksi yang cukup baik[18]. Selain itu, karena RMSE memiliki satuan yang sama dengan data yang diprediksi, seperti derajat Celsius untuk suhu atau milimeter untuk curah hujan, maka hasil evaluasi menjadi lebih mudah dipahami dan diinterpretasikan. Maka itu, RMSE menjadi salah satu metrik penting yang digunakan dalam penelitian ini untuk mengukur kinerja model secara kuantitatif. RMSE adalah akar dari rata-rata kuadrat selisih antara nilai prediksi dan nilai actual[19].

2.5 Analisis Hasil

Cara lain untuk menilai keakuratan keluaran prediksi model adalah dengan melihat RootMean Square Error (RMSE) dari metodologi prediksi. Rerata kuadrat jumlah error pada model prediksi menghasilkan nilai RMSE. Root Mean Square Error (RMSE) adalah metode sederhana yang sering diterapkan dalam berbagai investigasi prediksi[20]. Analisis hasil model Long Short-Term Memory (LSTM) dilakukan untuk menafsirkan kinerja model berdasarkan hasil pengujian dan evaluasi yang telah diperoleh. Tahap ini bertujuan untuk mengetahui sejauh mana model LSTM mampu mempelajari pola data deret waktu serta menghasilkan prediksi yang akurat dan stabil. Analisis tidak hanya berfokus pada nilai metrik evaluasi, tetapi juga pada perilaku model terhadap data aktual, seperti kesesuaian pola prediksi dengan data sebenarnya, proses konvergensi model selama pelatihan, serta kemampuan model dalam mengikuti tren perubahan suhu harian. Selain itu, hasil analisis juga digunakan untuk mengevaluasi pengaruh tahapan prapemrosesan data, pembentukan sliding window, dan penggunaan parameter cuaca multivariat terhadap performa model dalam menghasilkan prediksi

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Ringkasan data cuaca harian yang digunakan dalam penelitian ini disajikan pada Tabel 1. Tabel tersebut menampilkan contoh data meteorologi yang terdiri atas beberapa parameter cuaca yang digunakan sebagai masukan dalam proses pembangunan model Long Short-Term Memory (LSTM). Dataset yang digunakan terdiri dari 380 data cuaca harian di Kota Bima tahun 2025 yang didapatkan dari Badan Meteorologi, Klimatologi, dan Geofisika. Variabel yang digunakan mencakup suhu terendah (TN), suhu tertinggi (TX), suhu rata-rata (TAVG), kelembapan udara rata-rata (RH_AVG), curah hujan (RR), durasi penyinaran matahari (SS), kecepatan angin tertinggi (FF_X), arah angin tertinggi (DDD_X), kecepatan angin rata-rata (FF_AVG), dan arah angin yang paling dominan (DDD_CAR). Semua variabel memiliki pengukuran setiap hari, sehingga bisa dianggap sebagai data deret waktu multivariat. Dari tabel 1 dapat dilihat bahwa suhu rata-rata setiap hari berada di antara 26-28 °C dan tingkat kelembapan relatifnya cukup tinggi. Curah hujan berbeda-beda secara signifikan, mulai dari tidak hujan sama sekali hingga lebih dari 40 mm, sedangkan durasi sinar matahari juga mengalami perubahan. Perbedaan antarparameter tersebut menunjukkan bahwa hubungan antarvariabel tidak berbentuk garis lurus, sehingga dibutuhkan model yang bisa mempelajari ketergantungan antarparameter secara bersamaan dalam waktu yang sama.

Tabel 1. Tabel Cuaca

NO	TANGGAL	TN	TX	TAVG	RH_AVG	RR	SS	FF_X	DDD_X	FF_AVG	DDD_CAR
0	01-01-2025	25.6	30.8	26.4	89.0	0	6.7	5.0	110.0	1.0	C
1	02-01-2025	24.8	30.0	26.6	90.0	8.6	0.9	5.0	320.0	2.0	C
2	03-01-2025	25.0	29.8	26.8	88.0	1	0.7	4.0	170.0	1.0	SE
3	04-01-2025	24.6	31.0	26.9	87.0	0.3	0.3	3.0	120.0	1.0	C
4	05-01-2025	24.6	29.6	26.0	93.0	2	0.6	7.0	10.0	1.0	C

Secara keseluruhan, data awal menunjukkan bahwa kondisi cuaca selama lima hari pertama bulan Januari 2025 ditandai oleh suhu udara yang relatif stabil, kelembapan udara yang tinggi, curah hujan yang berubah-ubah, penyinaran matahari yang bervariasi, serta kecepatan angin yang cenderung rendah. Karakteristik tersebut

menunjukkan adanya hubungan antarvariabel cuaca yang dapat dimanfaatkan dalam proses pembangunan model prediksi menggunakan algoritma Long Short-Term Memory (LSTM).

3.2 Pra-pemrosesan Data

3.2.1 Data Cleaning

Sebelum dilakukan proses data cleaning, dilakukan pemeriksaan terhadap kelengkapan data untuk mengidentifikasi keberadaan missing value. Hasil pemeriksaan tersebut disajikan pada Tabel 2 sebagai dasar dalam menentukan teknik prapemrosesan yang akan diterapkan.

Tabel 2. Hasil Data Cleaning

Kolom	Jumlah Missing Value
TANGGAL	0
TN	0
TX	0
TAVG	0
RH_AVG	0
RR	0
SS	0
FF_X	0
DDD_X	0
FF_AVG	0
DDD_CAR	13

Hampir seluruh variabel telah lengkap, sedangkan variabel DDD_CAR memiliki 13 nilai yang hilang. Nilai tersebut ditangani pada tahap prapemrosesan data agar tidak mengganggu proses pelatihan model. Selanjutnya seluruh variabel numerik dinormalisasi menggunakan MinMaxScaler sehingga seluruh fitur berada pada rentang 0-1. Proses normalisasi dilakukan karena setiap parameter memiliki satuan yang berbeda, misalnya suhu (°C), curah hujan (mm), kelembapan (%), dan lama penyinaran (jam). Penyamaan skala ini bertujuan agar proses pembelajaran LSTM tidak didominasi oleh variabel yang memiliki rentang nilai lebih besar

3.2.2 Pembentukan Variabel Kondisi Cuaca

Hasil pembentukan variabel kondisi cuaca berdasarkan parameter meteorologi disajikan pada Tabel 3. Tabel tersebut menunjukkan pengelompokan kondisi cuaca menjadi kategori cerah, mendung, dan hujan berdasarkan nilai parameter cuaca yang digunakan dalam penelitian.

Tabel 3. Normalisasi Data

NO	TAVG	RH_AVG	RR	RR	Kondisi Cuaca
0	26.4	89.0	0.0	6.7	Cerah
1	26.6	90.0	8.6	0.9	Hujan
2	26.8	88.0	1.0	0.7	Hujan
3	26.9	87.0	0.3	0.3	Hujan
4	26.0	93.0	2.0	0.6	Hujan
5	27.6	85.0	4.0	2.5	Hujan
6	28.0	86.0	0.0	7.7	Cerah
7	27.5	87.0	30.4	8.0	Hujan
8	26.2	92.0	0.0	8.0	Cerah
9	26.9	89.0	2.3	5.4	Hujan
10	27.0	87.0	8.9	4.6	Hujan
11	27.8	88.0	5.0	0.2	Hujan
12	28.1	86.0	46.2	8.0	Hujan
13	28.4	82.0	1.0	7.7	Hujan
14	27.9	87.0	0.0	7.8	Cerah
15	27.7	88.0	0.0	4.1	Cerah
16	27.9	89.0	0.0	1.2	Mendung
17	27.1	92.0	2.3	3.3	Hujan
18	27.2	88.0	15.0	0.9	Hujan
19	26.9	92.0	40.2	2.7	Hujan

Tabel 3 mencakup lima variabel, yaitu suhu rata-rata (TAVG), kelembapan udara rata-rata (RH_AVG), curah hujan (RR), durasi penyinaran matahari (SS), dan kondisi cuaca. Berdasarkan data yang ditunjukkan, suhu rata-rata berada antara 26,0-28,4 °C, kelembapan udara berkisar antara 82 -93%, sedangkan curah hujan bervariasi

dari 0,0mm hingga 46,2 mm. Variabel kondisi cuaca dibagi menjadi tiga jenis, yaitu Cerah, Mendung, dan Hujan, sesuai dengan ciri-ciri nilai curah hujan serta parameter cuaca lainnya. Hasil tersebut menunjukkan bahwa data mencakup berbagai kondisi cuaca yang beragam, sehingga bisa digunakan sebagai dasar dalam proses analisis dan pembuatan model prediksi cuaca dengan menggunakan (LSTM). Berdasarkan Gambar 3, ditampilkan proses normalisasi data dengan menggunakan metode Min-Max Scaling. Hasil normalisasi menunjukkan bahwa semua nilai data sudah berada dalam rentang 0 sampai 1, jadi setiap variabel memiliki skala yang sama. Proses tersebut dilakukan agar pelatihan model LSTM lebih stabil dan prosesnya menjadi lebih cepat menyusun jawaban yang benar.

3.2.3 Normalisasi Data

Berdasarkan Gambar 4, hasil normalisasi data cuaca menggunakan metode MinMaxScaler. Pada proses ini, setiap nilai pada variabel seperti TN (temperatur minimum), TX (temperatur maksimum), TAVG (temperatur rata-rata), RH_AVG (kelembapan udara), RR (curah hujan), SS (lama penyinaran matahari), dan FF_AVG (kecepatan angin rata-rata) diubah ke dalam rentang nilai 0 hingga 1. Tujuan normalisasi ini adalah agar semua variabel memiliki skala yang sama sehingga tidak ada satu variabel yang memiliki pengaruh lebih besar dibandingkan variabel lainnya saat proses pelatihan model LSTM. Sebagai contoh, pada data pertama nilai TN sebesar 0,8933, TX sebesar 0,2619, dan RR sebesar 0,0686, yang menunjukkan bahwa nilai tersebut merupakan hasil transformasi dari data asli ke dalam skala normalisasi.


Tabel 4. Normalisasi Data

N0	TN	TX	TAVG	RH_AVG	RR	SS	FF_AVG
1	0,8933	0,2619	0,3793	...	0,0668	0,8354	0,0000
2	0,7867	0,1667	0,4138	...	0,0665	0,1013	0,2500
3	0,8133	0,1429	0,4483	...	0,0070	0,0759	0,0000
...	...	...	...	...	...	...	...
363	0,9200	0,1786	0,5690	...	0,0008	0,4810	0,0000
364	0,8533	0,3214	0,5517	...	0,0930	0,0380	0,2500
365	0,7600	0,4048	0,6552	...	0,0493	1,0000	0,2500

Berdasarkan Tabel 4 Secara keseluruhan, hasil normalisasi menghasilkan 365 baris data dengan 7 variabel cuaca yang siap digunakan sebagai input model LSTM. Nilai yang mendekati 0 menunjukkan bahwa data tersebut berada di dekat nilai minimum pada variabelnya, sedangkan nilai yang mendekati 1 menunjukkan bahwa data berada di dekat nilai maksimum. Sebagai contoh, pada data ke-365 nilai SS sebesar 1,0000 menunjukkan bahwa lama penyinaran matahari pada hari tersebut merupakan nilai tertinggi dibandingkan data lainnya setelah dinormalisasi. Dengan proses normalisasi ini, model LSTM dapat mempelajari pola data dengan lebih baik, proses pelatihan menjadi lebih stabil, dan hasil prediksi yang dihasilkan diharapkan memiliki tingkat akurasi yang lebih baik.

3.2.4 Visualisasi Data Time Series Suhu Harian Kota Bima

Visualisasi pola perubahan suhu rata-rata harian selama periode pengamatan disajikan pada Gambar 2. Gambar tersebut memperlihatkan perubahan suhu dari waktu ke waktu sehingga dapat digunakan untuk mengidentifikasi pola, tren, dan fluktuasi suhu harian di Kota Bima sebelum dilakukan proses pemodelan menggunakan algoritma Long Short-Term Memory (LSTM).



Gambar 2. Time Series Suhu Rata-rata Harian

Berdasarkan Gambar 2 grafik time series, yang menunjukkan perubahan suhu harian di Kota Bima, khususnya nilai TAVG atau temperatur rata-rata harian selama jangka waktu 365 hari. Sumbu horizontal (X) menunjukkan urutan tanggal saat pengamatan dilakukan, sedangkan sumbu vertikal (Y) menunjukkan angka rata-rata suhu dalam satuan °C. Dari grafik bisa dilihat bahwa suhu setiap hari mengalami perubahan seiring berjalannya waktu dengan pola yang cukup berubah-ubah. Pada hari-hari umumnya, suhu berkisar antara 26-29 °C namun di beberapa waktu suhu bisa turun mendekati 24°C atau naik hingga sekitar 30 °C. Perubahan ini menunjukkan bahwa suhu di Kota Bima tidak selalu sama setiap hari, melainkan dipengaruhi oleh cuaca yang terus berubah setiap harinya.

3.3 Perancangan dan Pelatihan Model LSTM

3.3.1 Bangun model LSTM

Arsitektur model Long Short-Term Memory (LSTM) yang digunakan dalam penelitian ini disajikan pada Tabel 5. Tabel tersebut menampilkan susunan layer, bentuk keluaran (output shape), serta jumlah parameter (parameter) pada setiap layer yang digunakan dalam proses pelatihan model.


Tabel 5. Arsitektur Model Long Short-Term Memory (LSTM)

Layer (type)	Output shape	Param #
lstm (LSTM)	(None, 64)	18,432
dropout (Dropout)	(None, 64)	0
dense (Dense)	(None, 32)	2,080
dense_1 (Dense)	(None, 1)	33
Total params : 20,545, (80,25 KB)		
Trainable Params : 20,545 (80,25 KB)		
Non-trainable Params 0 (0,00 B)		

Model LSTM dibuat dengan satu lapisan LSTM yang memiliki 64 unit, lalu diikuti oleh dropout dan dense. Selama masa pelatihan, grafik loss dari pelatihan dan validasi menunjukkan tren yang menurun dan tetap stabil sampai akhir proses pelatihan. Kedua kurva tidak menunjukkan perbedaan yang terlalu besar, sehingga model dapat memahami pola data tanpa menunjukkan tanda-tanda overfitting yang nyata. Namun, kurva loss belum sepenuhnya menunjukkan kemampuan model dalam melakukan generalisasi karena jumlah data yang digunakan untuk melatih jaringan saraf masih terbatas. Oleh karena itu, hasil penelitian ini harus dipahami berdasarkan karakteristik dari dataset yang digunakan. Berdasarkan gambar 5 di bawah ini.

3.3.2 Loss Training LSTM

Untuk mengevaluasi kinerja model selama proses pelatihan, Gambar 3 menyajikan grafik perubahan nilai training loss dan validation loss pada setiap epoch. Grafik ini digunakan untuk mengamati tingkat konvergensi model serta mendeteksi kemungkinan terjadinya overfitting atau underfitting.



Gambar 3. Arsitektur Model Long Short-Term Memory (LSTM)


Grafik perubahan nilai loss pada tahap pelatihan dan validasi selama 100 kali pengulangan (epoch) dalam proses melatih model Long Short-Term Memory (LSTM). Garis biru menunjukkan loss dari pelatihan, yaitu seberapa besar kesalahan model saat berlatih dengan data pelatihan, sedangkan garis oranye menunjukkan loss validasi, yaitu seberapa besar kesalahan model saat diuji dengan data validasi. Pada awal pelatihan, nilai loss training terlihat cukup tinggi, namun kemudian turun secara perlahan hingga mendekati angka 0,027 di akhir proses pelatihan. Penurunan angka loss ini menunjukkan bahwa model mulai memahami pola di dalam data cuaca yang digunakan, sehingga kesalahan dalam menjelaskan data pelatihan menjadi lebih kecil. Sementara itu, nilai

loss validasi berada dalam rentang 0,023-0,033 dan secara umum tetap stabil meskipun ada sedikit perubahan pada beberapa tahap pelatihan.

3.4 Pengujian dan Evaluasi Model

3.4.1 Grafik Aktual dan Prediksi

Grafik pada Gambar 4 menunjukkan bahwa grafik yang membandingkan data nyata dengan data prediksi TAVG (suhu rata-rata) berdasarkan model Long Short-Term Memory (LSTM) pada data uji. Garis berwarna biru menunjukkan suhu sesungguhnya, sedangkan garis oranye menunjukkan suhu yang diprediksi oleh model. Sumbu horizontal (X) menunjukkan urutan hari dari data pengujian, sedangkan sumbu vertikal (Y) menunjukkan angka suhu dalam satuan°C. Dari grafik dapat dilihat bahwa hasil prediksi memiliki pola yang secara umum sesuai dengan perubahan data aktual, meskipun di beberapa titik masih terdapat perbedaan antara nilai prediksi dan nilai sebenarnya. Ini menunjukkan bahwa model LSTM berhasil memahami pola perubahan suhu berdasarkan data historis yang digunakan dalam proses pelatihan.



Gambar 4. Hasil Prediksi TAVG terhadap Data Aktual

Selain itu, dapat dilihat bahwa garis prediksi terasa lebih lembut dibandingkan dengan garis data yang sebenarnya. Hal ini terjadi karena model LSTM membuat prediksi berdasarkan pola yang sudah dipelajari dari data sebelumnya, sehingga perubahan nilai yang sangat besar atau sangat kecil tidak selalu bisa diprediksi dengan tepat. Beberapa titik tertinggi dalam data nyata tidak bisa diikuti sepenuhnya oleh hasil prediksi, sehingga masih ada perbedaan atau kesalahan pada beberapa hari tertentu. Meskipun begitu, secara keseluruhan hasil prediksi tetap mendekati nilai sebenarnya, yang menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam memperkirakan suhu rata-rata harian. Hasil ini juga didukung oleh nilai Root Mean Square Error (RMSE) yang telah diperoleh sebelumnya, sehingga dapat disimpulkan bahwa model LSTM mampu memberikan prediksi yang cukup akurat terhadap data cuaca yang digunakan dalam penelitian ini.

3.4.2 Hasil Prediksi Temperatur Rata-rata (TAVG)

Berdasarkan proses pengujian model Long Short-Term Memory (LSTM), diperoleh hasil prediksi temperatur rata-rata (TAVG) yang disajikan pada Tabel 6. Tabel tersebut menunjukkan nilai aktual, nilai prediksi, dan selisih hasil prediksi terhadap data aktual pada setiap hari pengujian sehingga dapat digunakan untuk mengevaluasi kinerja model yang telah dibangun.

Tabel 6. Hasil Prediksi Temperatur Rata-Rata (TAVG)

Hari	Tanggal	Nilai Aktual	Nilai Prediksi	Selisih
0	26-10-2025	2.0	2.06	-0.06
1	27-10-2025	2.0	2.12	-0.12
2	28-10-2025	1.0	2.06	-1.06
3	29-10-2025	1.0	1.89	-0.89
4	30-10-2025	2.0	1.78	0.22
..	...	...	...	...
62	27-12-2025	2.0	2.01	-0.01
63	28-12-2025	1.0	1.86	-0.01
64	29-12-2025	1.0	1.80	-0.80
65	30-12-2025	2.0	1.74	0.26
66	31-12-2025	2.0	1.84	0.16

Berdasarkan hasil yang didapat, tabel menunjukkan 67 data uji yang digunakan untuk menilai seberapa baik model LSTM dalam memprediksi suhu rata-rata (TAVG). Dari hasil tersebut terlihat bahwa sebagian besar nilai prediksi memiliki perbedaan yang tidak terlalu besar dibandingkan dengan nilai yang sebenarnya. Misalnya, pada tanggal 26 Oktober 2025, nilai sebenarnya adalah 2,00, sedangkan nilai yang diprediksi adalah 2,06, sehingga terdapat perbedaan sebesar -0,06. Hal ini menunjukkan bahwa hasil prediksi model sangat dekat dengan nilai aktual. Meskipun ada beberapa hari yang masih menunjukkan perbedaan cukup signifikan, seperti pada tanggal 28 Oktober 2025 dengan perbedaan -1,06, secara keseluruhan model berhasil mengikuti pola perubahan data nyata dengan cukup baik.

3.5 Analisi Hasil

Berdasarkan Tabel 7, Tabel tersebut menampilkan jumlah data yang digunakan, pembagian data pelatihan dan pengujian, ukuran window, serta nilai Root Mean Square Error (RMSE) yang diperoleh dari hasil evaluasi model.

Tabel 7. Hasil Pembagian Data dan Evaluasi Model LSTM

No	Parameter	Nilai
1	Jumlah Data	380
2	Data Training	268
3	Data Testing	67
4	Window Size	30
5	Nilai RMSE	0.7242

Berdasarkan Tabel 7, penelitian ini menggunakan 380 data cuaca, dengan 268 data sebagai data pelatihan dan 67 data sebagai data pengujian. Model LSTM dibangun menggunakan window size 30, sehingga setiap prediksi memanfaatkan informasi dari 30 data sebelumnya. Hasil evaluasi menunjukkan nilai RMSE sebesar 0,7242, yang mengindikasikan bahwa model memiliki tingkat kesalahan prediksi yang relatif rendah. Nilai tersebut menunjukkan bahwa model mampu mempelajari pola perubahan suhu harian dengan baik sehingga menghasilkan prediksi yang mendekati data aktual.

3.6 Pembahasan

Hasil penelitian menunjukkan bahwa model Long Short-Term Memory (LSTM) mampu memprediksi suhu rata-rata harian di Kota Bima dengan nilai Root Mean Square Error (RMSE) sebesar 0,7242, yang menunjukkan tingkat kesalahan prediksi relatif rendah. Hasil ini sejalan dengan penelitian Yusuf et al. (2023) yang memperoleh nilai RMSE 0,98162 pada prediksi cuaca ekstrem di Jawa Barat, serta penelitian Lattifia et al[2]. (2022) yang menghasilkan RMSE 1,7444 pada prediksi cuaca harian. Kesamaan hasil tersebut menunjukkan bahwa algoritma LSTM efektif dalam memodelkan data cuaca berbasis deret waktu karena mampu mempelajari pola temporal dari data historis[12].

Selain itu, penelitian ini juga mendukung penelitian Firdaus dan Paputungan (2022) yang menerapkan LSTM untuk prediksi curah hujan di Kota Bandung dengan RMSE terbaik sebesar 12,21 pada data pelatihan dan 8,78 pada data pengujian[9]. Perbedaan nilai RMSE antarpencapaian dipengaruhi oleh perbedaan jenis data, variabel yang digunakan, karakteristik wilayah, jumlah data, dan target prediksi, sehingga tidak dapat dibandingkan secara langsung. Kontribusi penelitian ini terletak pada penerapan LSTM menggunakan data meteorologi multivariat Kota Bima dengan tahapan prapemrosesan berupa moving average, MinMaxScaler, dan sliding window 30 hari, sehingga dapat menjadi referensi awal dalam pengembangan model prediksi cuaca berbasis deep learning di wilayah dengan karakteristik iklim yang serupa.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa algoritma Long Short-Term Memory (LSTM) bisa digunakan untuk memprediksi suhu rata-rata harian (TAVG) di Kota Bima. Pemrediksiannya menggunakan data meteorologi yang mencakup suhu minimum (TN), suhu maksimum (TX), suhu rata-rata (TAVG), kelembapan udara rata-rata (RH_AVG), curah hujan (RR), durasi penyinaran matahari (SS), dan kecepatan angin rata-rata (FF_AVG). Sebelum model dilatih, dilakukan beberapa langkah persiapan yaitu mengatasi data yang hilang, memproses data dengan metode MinMaxScaler, serta membuat data berbentuk time series dengan menggunakan metode sliding window selama 30 hari. Hasil pengujian menunjukkan model menghasilkan nilai RMSE sebesar 0,7242. Angka ini menunjukkan tingkat kesalahan dalam prediksi relatif kecil, artinya model mampu memahami pola perubahan suhu harian dengan cukup baik.

Kontribusi penelitian ini adalah menyediakan implementasi model prediksi suhu harian berbasis LSTM menggunakan data meteorologi multivariat Kota Bima yang dipadukan dengan tahapan prapemrosesan data secara sistematis. Hasil penelitian menunjukkan bahwa pendekatan tersebut mampu memodelkan pola temporal suhu harian dengan nilai RMSE sebesar 0,7242, sehingga dapat menjadi referensi awal dalam pengembangan model prediksi cuaca berbasis deep learning pada wilayah dengan karakteristik iklim yang serupa. Selain memberikan

kontribusi secara akademis sebagai studi awal penerapan LSTM pada data meteorologi Kota Bima, penelitian ini juga memiliki potensi penerapan praktis sebagai sistem pendukung analisis prakiraan cuaca di lingkungan BMKG. Selain itu, hasil prediksi pada data pengujian menunjukkan bahwa sebagian besar nilai prediksi memiliki perbedaan yang tidak terlalu besar dibandingkan dengan nilai sebenarnya, sehingga model tersebut mampu mengikuti perubahan suhu harian dengan cukup tepat. Model ini juga bisa menunjukkan kondisi cuaca setiap hari, seperti cuaca cerah, mendung, atau hujan, berdasarkan prediksi suhu yang digabungkan dengan parameter seperti curah hujan, tingkat kelembapan udara, dan lama matahari bersinar. Dengan demikian, model LSTM memiliki kemungkinan untuk digunakan sebagai salah satu cara bantu dalam memprediksi cuaca harian di Kota Bima. Meskipun begitu, penelitian ini hanya menggunakan satu algoritma, jadi pada penelitian berikutnya dianjurkan untuk membandingkan hasil LSTM dengan metode lain atau menggunakan data dengan jangka waktu yang lebih lama agar prediksi bisa lebih akurat.

REFERENCES

- [1] Y. E. N. Nugraha, I. Ariawan, and W. A. Arifin, “Weather Forecast From Time Series Data Using Lstm Algorithm,” *J. Teknol. Inf. Dan Komun.*, vol. 14, no. 1, pp. 144–152, 2023, doi: 10.51903/jtikp.v14i1.531.
- [2] M. Maulana Yusuf, M. Martanto, and U. Hayati, “Analisis Pola Cuaca Extrem Menggunakan Long Short Term Memory Pada Wilayah Jawa Barat,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 6, pp. 3781–3788, 2024, doi: 10.36040/jati.v7i6.8288.
- [3] H. T. A. Simanjuntak, A. Lumbanraja, G. Samosir, and Regita, “Prediksi Single-Step dan Multi-Step Data Cuaca Menggunakan Model Long Short-Term Memory dan Sarima,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 2, pp. 399–410, 2025, doi: 10.25126/jtiik.2025129444.
- [4] P. C. Adhany, C. Wulandari, B. Intan, and B. Santoso, “Prediksi Padi Menggunakan Algoritma Long Short Term Memory,” *J. Informatics Manag. Inf. Technol.*, vol. 5, no. 2, pp. 120–127, 2025, doi: 10.47065/jimat.v5i2.496.
- [5] N. Januari, E. F. Aritonang, A. Arif, O. D. Tarigan, D. J. Sinaga, and A. Sinuraya, “Prediksi Akurat Output Daya Jangka Pendek PLTS Menggunakan Algoritma Long Short-Term Memory (LSTM) Jaringan Saraf Tiruan Berbasis Data Cuaca Real-Time Pembangkit Listrik Tenaga Surya (PLTS) merupakan langkah strategis dalam stabilitas dan keandalan si,” vol. 3, no. 1, pp. 364–370, 2026, doi: 10.61722/jinu.v3i1.7593.
- [6] D. D. N. Cahyo and A. Sunyoto, “Analisis Perbandingan Klasifikasi dalam Data Mining pada Prediksi Hujan dengan menggunakan Algoritma LSTM dan GRU,” *J. Sains dan Inform.*, vol. 11, no. 1, pp. 40–49, 2025, doi: 10.34128/jsi.v11i1.1212.
- [7] N. Nurzaenab et al., “Evaluasi Performa Metode Long Short Term Memory (Lstm) Dan Recurrent Neural Network (Rnn) Pada Analisis Sentimen Komentar Pengguna Aplikasi Kitalulus,” *Jtriste*, vol. 12, no. 1, pp. 86–92, 2025, doi: 10.55645/jtriste.v12i1.614.
- [8] F. A. R. ALDI and N. D. Nathasia, “Prediksi Harga Dan Kinerja Aset Bitcoin Menggunakan Algoritma Long Short-Term Memory,” *J. Fasikom*, vol. 15, no. 1, pp. 68–76, 2025, doi: 10.37859/jf.v15i1.8902.
- [9] R. Farikhul 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, 2022, doi: 10.54082/jupin.99.
- [10] S. Hidayatullah and A. Cherid, “Prediksi Temperatur Cuaca di Negara Norwegia Menggunakan Metode LSTM,” *Simkom*, vol. 8, no. 2, pp. 187–198, 2023, doi: 10.51717/simkom.v8i2.192.
- [11] L. T. M. Lstm, “PREDIKSI PARAMETER CUACA MENGGUNAKAN DEEP LEARNING LONG-SHORT TERM MEMORY (LSTM),” pp. 55–67, 2019.
- [12] T. Lattifia, P. W. Buana, and N. K. D. Rusjayanthi, “Model Prediksi Cuaca Menggunakan Metode LSTM,” *JITTER J. Ilm. Teknol. dan Komput.*, vol. 3, no. 1, p. 994, 2022, doi: 10.24843/jtrti.2022.v03.i01.p35.
- [13] M. M. Yusuf, U. Hayati, T. Informatika, M. Informatika, and K. Cirebon, “Analisis Pola Cuaca Extrem Menggunakan Long Short Term Memory pada Wilayah Jawa Barat 1,3,” vol. 7, no. 6, pp. 3781–3788, 2023, doi: 10.36040/jati.v7i6.8288.
- [14] M. Rizki, S. Basuki, and Y. Azhar, “Implementasi Deep Learning Menggunakan Arsitektur Long Short Term Memory(LSTM) Untuk Prediksi Curah Hujan Kota Malang,” *J. Repos.*, vol. 2, no. 3, pp. 331–338, 2020, doi: 10.22219/repositor.v2i3.470.
- [15] M. R. Prasetya, R. C. Dewi, A. H. Asyhar, and A. Hamid, “Prediksi Curah Hujan Harian Menggunakan Metode Principal Component Analysis (PCA) dan Long Short-Term Memory (LSTM),” vol. 6, no. 1, pp. 1–13, 2026, doi: 10.51454/decode.v6i1.1451.
- [16] Y. Ashari and A. Suhendar, “Implementasi Algoritma Long Short-Term Memory (Lstm) Untuk Memprediksi Harga Beras Di Jawa Tengah Berdasarkan Cuaca,” *Djtechno J. Teknol. Inf.*, vol. 5, no. 3, pp. 624–636, 2024, doi: 10.46576/djtechno.v5i3.5136.
- [17] J. Badriyah, A. Fariza, and T. Harsono, “Prediksi Curah Hujan Menggunakan Long Short Term Memory,” *J. Media Inform. Budidarma*, vol. 6, no. 3, p. 1297, 2022, doi: 10.30865/mib.v6i3.4008.
- [18] I. Wijaya, H. Herlawati, and R. Sari, “Prediksi Curah Hujan Di Kabupaten Bogor Menggunakan Long Short-Term Memory Dan Gemma 2,” *J. Komtika (Komputasi dan Inform.*, vol. 9, no. 1, pp. 147–157, 2025, doi: 10.31603/komtika.v9i1.13639.
- [19] L. S. Harahap and M. R. Adrian, “PREDIKSI CURAH HUJAN BULANAN DI MEDAN MENGGUNAKAN METODE LONG SHORT-TERM MEMORY,” vol. 02, pp. 1–6, 2026, doi: 10.70134/jitifna.v2i1.969.
- [20] J. Nasional, S. Informasi, I. Hapsari, and S. Pandya, “Evaluasi Model Prediksi Curah Hujan Berbasis Machine Learning di Kota Bandung,” vol. 02, pp. 136–143, 2025, doi: 10.25077/TEKNOSI.v1i2.2025.136-143.