

PREDIKSI TINGKAT CURAH HUJAN KOTA MATARAM MENGUNAKAN *LONG SHORT-TERM MEMORY*

Dimas Anggrawan Hadinata¹, Irene Rainbow Kewa Somi², Luluk Kartika³, Tri Maryono Rusadi^{4§},
Siska Aprilia Hardiyanti⁵

¹Matematika, FMIPA, Universitas Mataram [Email: dimasanggrawanhadinata@gmail.com]

²Matematika, FMIPA, Universitas Mataram [Email: irenemershy@gmail.com]

³Matematika, FMIPA, Universitas Mataram [Email: luluk.kartika13@gmail.com]

⁴Matematika, FMIPA, Universitas Mataram [Email: rusadi.tm@staff.unram.ac.id]

⁵Teknologi Rekayasa Perangkat Lunak, Politeknik Negeri Banyuwangi [Email: siska_aprilia3@poliwangi.ac.id]

§ *Corresponding Author*

ABSTRACT

Rainfall is an important weather parameter that significantly influences the agricultural sector and regional planning. The City of Mataram, as the center of social and economic activities in West Nusa Tenggara Province, requires an accurate rainfall prediction method. This study aims to predict daily rainfall in Mataram City using a multivariate long short-term memory (LSTM) approach. The data used consist of daily observations from BMKG, with input variables including average temperature, average humidity, average wind speed, and average air pressure. The dataset is structured as a time series using a sliding window approach with a 7-day lookback period and is divided into 80% training data and 20% testing data. The LSTM model is constructed with two LSTM layers containing 64 and 32 units, respectively, complemented by a 0,2 drop out layer and a Dense layer as the output for prediction. Evaluation using MAE and RMSE indicates that a configuration of 100 epochs and a batch size of 16 provides the best performance, achieving MAE of 4,020 mm and RMSE of 7,915 mm on the testing data, demonstrating the model's capability to predict daily rainfall in a stable manner.

Keywords: *Prediction, Long Short-Term Memory, Mataram, Rainfall.*

1. PENDAHULUAN

Cuaca merupakan salah satu faktor penting yang sangat memengaruhi kehidupan manusia. Salah satu unsur cuaca yang memiliki peranan signifikan adalah curah hujan, yaitu jumlah air hujan yang jatuh ke permukaan bumi dalam satuan waktu tertentu. Besarnya curah hujan dipengaruhi oleh beberapa faktor meteorologis, seperti kelembapan udara, tekanan udara, suhu udara, dan kecepatan angin (Mukid & Sugito, 2013).

Pengamatan dan pemahaman terhadap kondisi curah hujan menjadi hal yang penting untuk menunjang berbagai aktivitas manusia. Curah hujan memiliki pengaruh yang besar terhadap berbagai sektor, antara lain pertanian, industri, dan perdagangan. Oleh karena itu, prediksi curah hujan perlu dilakukan secara tepat agar dapat dimanfaatkan sebagai dasar perencanaan dan pengambilan keputusan oleh pihak-pihak yang membutuhkan (Muflih, 2019).

Kota Mataram yang terletak di Pulau Lombok, Provinsi Nusa Tenggara Barat, merupakan wilayah dengan aktivitas ekonomi yang sangat dipengaruhi oleh pola curah hujan, baik pada sektor pertanian, pariwisata, maupun pengelolaan lingkungan (Kirono, 2016). Kondisi tersebut menjadikan prediksi curah hujan yang akurat sebagai kebutuhan penting dalam mendukung perencanaan dan pengambilan kebijakan. Salah satu pendekatan yang dapat digunakan untuk memprediksi curah hujan adalah model LSTM, yang mampu memodelkan data deret waktu dengan ketergantungan jangka panjang.

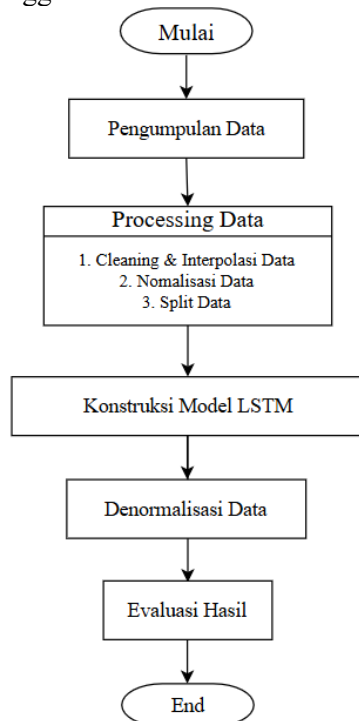
Beberapa penelitian sebelumnya yang dilakukan oleh Rizki et al., (2020) menggunakan model LSTM mampu memprediksi curah hujan di Kota Malang dan menghasilkan kinerja yang baik dengan nilai RMSE sebesar 11,288, dimana data curah hujan terendah yaitu 0 mm dan

tertinggi mencapai 683 mm. Sementara itu, Musfiroh et al. (2023) menunjukkan bahwa penerapan kombinasi *principal component analysis* (PCA) dan LSTM mampu menghasilkan prediksi curah hujan harian yang sangat akurat di Kabupaten Luwu Utara, termasuk dalam memodelkan kejadian hujan dengan intensitas sangat lebat.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk memprediksi curah hujan harian di Kota Mataram menggunakan metode LSTM sebagai pendekatan pemodelan deret waktu. Hasil penelitian ini diharapkan dapat memberikan informasi prediksi yang lebih akurat dan menjadi referensi bagi pihak terkait dalam mendukung perencanaan serta pengambilan keputusan yang berkaitan dengan kondisi curah hujan di Kota Mataram.

2. METODE PENELITIAN

Berikut tahapan dan penjelasan penelitian yang menggunakan metode LSTM:



Gambar 1. Diagram Alir Penelitian

2.1 Pengumpulan Data

Data yang digunakan berupa data sekunder yang diperoleh melalui situs resmi BMKG. Data yang digunakan berupa data harian kondisi cuaca di Kota Mataram yang meliputi suhu rata-rata, kelembapan udara rata-rata, kecepatan angin rata-rata, tekanan udara rata-rata dan

curah hujan. Jumlah data yang digunakan sebanyak 1824 data tahun 2019-2023.

2.2 Processing Data

Tahapan pengolahan data pada penelitian ini diawali dengan pembersihan data (*data cleaning*) untuk mengidentifikasi dan menghapus data yang tidak lengkap, duplikasi, serta nilai tidak wajar yang berpotensi mengganggu proses pemodelan (Yasin & Khorsheed, 2025). Selanjutnya dilakukan interpolasi data untuk menangani nilai yang hilang (*missing values*) sehingga deret waktu tetap kontinu dan pola temporal data dapat dipertahankan. Proses selanjutnya adalah normalisasi data menggunakan *Min-Max Scaling* yakni dengan menyamakan skala nilai ke rentang tertentu (0-1), sehingga setiap variabel memiliki pengaruh yang seimbang dan tidak mendominasi satu sama lain dalam analisis atau pemodelan (Pranolo, 2024).

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Keterangan :

x' = Nilai hasil normalisasi

x = Nilai data aktual yang dinormalisasi

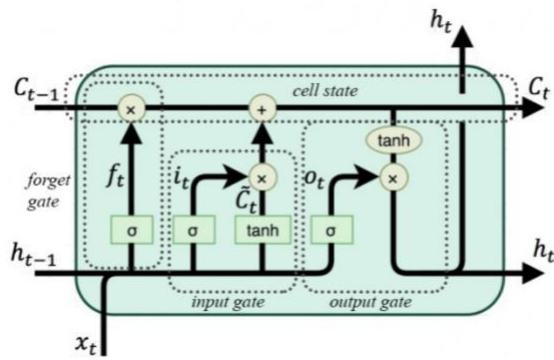
x_{min} = Nilai minimum dari data aktual

x_{max} = Nilai maksimum dari data aktual

Tahap terakhir adalah pembagian data (*data splitting*) menjadi 80% data *training* dan 20% data *testing* untuk mengevaluasi kemampuan model dalam melakukan prediksi curah hujan secara akurat (Saputra, 2023).

2.3 Long Shorty-Term Memory

LSTM merupakan salah satu pengembangan dari *recurrent neural network* (RNN) yang dirancang untuk mengatasi permasalahan *vanishing gradient* dan *exploding gradient* dalam pemodelan data deret waktu jangka panjang (Hidayatullah & Cherid, 2023). Dalam proses pemodelan LSTM, beberapa aspek perlu diperhatikan untuk memperoleh kinerja model yang optimal, antara lain penentuan jumlah *hidden layer* dan pemilihan hyperparameter yang sesuai. Selain itu, LSTM mampu menghasilkan keluaran yang relevan dengan mempertimbangkan ketergantungan temporal pada data masukan (Wiranda & Sadikin, 2019).



Gambar 2. Arsitektur dari LSTM

Gambar 2 menunjukkan arsitektur LSTM yang digunakan untuk memodelkan data deret waktu dengan mempertahankan informasi jangka panjang. Pada waktu ke- t , LSTM menerima input berupa x_t , *hidden state* sebelumnya h_{t-1} , dan *cell state* sebelumnya C_{t-1} . Proses pertama dilakukan oleh *forget gate* yang dirumuskan sebagai:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2)$$

Dengan σ merupakan fungsi aktivasi sigmoid, W_f merupakan bobot dari *forget gate*, b_f merupakan bias dari *forget gate*. *Forget gate* ini berfungsi untuk menentukan bagian informasi dari C_{t-1} yang dipertahankan atau dibuang. Selanjutnya, *input gate* i_t mengatur informasi baru melalui persamaan:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (3)$$

Dengan W_i merupakan bobot dari *input gate*, b_i merupakan bias dari *input gate*. Kemudian kandidat *cell state* \tilde{C}_t diperoleh dengan fungsi aktivasi *tanh* dari persamaan:

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (4)$$

Update Cell State dilakukan dengan mengombinasikan informasi lama dan baru melalui persamaan:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (5)$$

Dari persamaan (5) memungkinkan penyimpanan informasi penting dalam jangka panjang. Selanjutnya, *output gate* o_t menentukan keluaran dengan persamaan:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (6)$$

Dengan W_o merupakan bobot dari *output gate*, b_o merupakan bias dari *output gate*. Selanjutnya *Hidden State (Output)* h_t diteruskan ke langkah berikutnya yang dihitung dari persamaan:

$$h_t = o_t \cdot \tanh(C_t) \quad (7)$$

Dalam arsitektur ini, fungsi aktivasi sigmoid

σ digunakan untuk mengontrol aliran informasi pada setiap gerbang dengan nilai antara 0 hingga 1, sedangkan fungsi *tanh* digunakan untuk membentuk representasi nilai memori dalam rentang -1 hingga 1. Mekanisme ini memungkinkan LSTM menangkap dependensi jangka panjang secara efektif dan tetap menjadi salah satu model utama dalam pemodelan data sekuensial modern (Wanzhen, 2024).

2.4 Denormalisasi data

Hasil prediksi yang diperoleh dari model LSTM masih berada dalam bentuk data ternormalisasi, sehingga diperlukan proses denormalisasi. Proses ini bertujuan agar hasil prediksi dapat diinterpretasikan secara langsung dan dibandingkan dengan data aktual. Nilai hasil denormalisasi selanjutnya digunakan untuk menghitung nilai galat (*error*) pada data pelatihan dan data pengujian sebagai dasar evaluasi kinerja model (Pranolo, 2024).

Untuk rumus denormalisasi sebagai berikut:

$$d' = x' (x_{max} - x_{min}) + x_{min} \quad (8)$$

Keterangan:

- d' = Nilai hasil denormalisasi
- x' = Nilai data normalisasi
- x_{min} = Nilai minimum dari data actual
- x_{max} = Nilai maksimum dari data actual

2.5 Evaluasi

Evaluasi kinerja model LSTM dalam memprediksi curah hujan dilakukan menggunakan *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE). Kedua metrik ini digunakan untuk mengukur tingkat akurasi hasil prediksi curah hujan dengan membandingkan nilai prediksi terhadap data curah hujan aktual, serta umum digunakan dalam penelitian peramalan deret waktu meteorologi.

Rumus untuk RMSE sebagai berikut :

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (9)$$

Dengan \hat{y}_i merupakan nilai hasil prediksi, y_i nilai aktual dan n adalah jumlah data. Nilai RMSE yang semakin mendekati nol menunjukkan bahwa model LSTM memiliki kesalahan prediksi yang semakin kecil, sehingga mampu merepresentasikan pola curah hujan aktual dengan baik. Sebaliknya, nilai RMSE yang besar mengindikasikan bahwa perbedaan

antara nilai prediksi dan nilai aktual masih cukup signifikan.

Selanjutnya rumus untuk MAE sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

Dengan \hat{y}_i merupakan nilai hasil prediksi, y_i nilai aktual dan n adalah jumlah data. Nilai MAE yang mendekati nol menunjukkan bahwa rata-rata kesalahan prediksi curah hujan relatif kecil, sedangkan nilai MAE yang besar mengindikasikan rendahnya akurasi model dalam memprediksi curah hujan.

3. HASIL DAN PEMBAHASAN

3.1 Analisis Data Curah Hujan

Pada penelitian ini, curah hujan digunakan sebagai variabel yang diprediksi, sedangkan

empat variabel cuaca lainnya, yaitu suhu rata-rata, kelembapan udara rata-rata, kecepatan angin rata-rata dan tekanan udara rata-rata digunakan sebagai variabel input. Seluruh data disusun dalam bentuk deret waktu (*time series*) untuk keperluan pelatihan dan pengujian model LSTM.


Data tersebut menunjukkan pola curah hujan harian di Kota Mataram yang bersifat fluktuatif dengan variasi intensitas hujan yang cukup tinggi pada periode tertentu.

Pola ini mencerminkan karakteristik data curah hujan yang tidak stasioner dan mengandung nilai ekstrem, sehingga memerlukan metode prediksi yang mampu menangkap ketergantungan temporal jangka panjang.

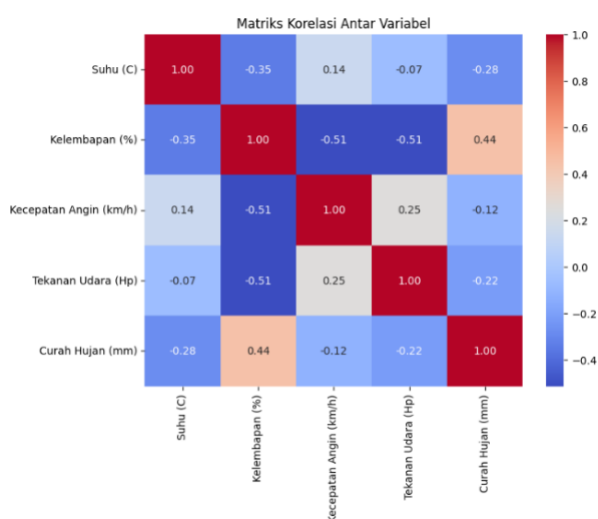
Table 1. Data Harian Curah Hujan di Kota Mataram

Tanggal	Suhu (C)	Kelembapan (%)	Kecepatan Angin (km/h)	Tekanan Udara (Hp)	Curah Hujan (mm)
01/01/19	25,70	95,20	4,90	1008,90	101,10
02/01/19	26,00	89,80	6,30	1009,20	17,50
03/01/19	24,60	95,20	1,30	1011,00	35,20
04/01/19	26,70	88,10	7,40	1011,60	2,10
05/01/19	27,00	85,90	6,10	1011,50	1,90
06/01/19	25,90	87,50	4,40	1011,00	0,20
07/01/19	27,10	84,20	6,30	1010,00	3,00
⋮	⋮	⋮	⋮	⋮	⋮
25/12/23	28,9	81,7	9,7	1010,2	0,00
26/12/23	28,9	79,3	8,6	1010,9	0,00
27/12/23	28,6	83,5	8,3	1011,3	0,60
28/12/23	28,3	87,3	7,2	1010,2	15,00
29/12/23	29,0	81,7	8,3	1009,1	0,00
30/12/23	29,4	80,9	6,7	1008,1	10,00
31/12/23	29,2	81,8	7,6	1008,8	0,01

Sumber: dataonline.bmkg.go.id



Gambar 3. Visualisasi Data harian Curah Hujan di Kota Mataram 2019-2023



Gambar 4. Matriks Korelasi Antar Variabel Data Aktual

Berdasarkan matriks korelasi, hubungan antara empat variabel meteorologi terhadap curah hujan menunjukkan pola yang bervariasi. Kelembapan udara rata-rata memiliki korelasi positif sebesar 0,44 terhadap curah hujan, yang berarti terdapat hubungan positif dengan tingkat korelasi kuat. Hal ini menunjukkan bahwa semakin tinggi kelembapan udara, maka curah hujan cenderung meningkat.

Sementara itu, suhu rata-rata memiliki korelasi negatif sebesar $-0,28$ menunjukkan hubungan negatif lemah yang artinya, peningkatan suhu cenderung diikuti oleh sedikit penurunan curah hujan, meskipun pengaruhnya tidak terlalu kuat. Tekanan udara rata-rata juga menunjukkan korelasi negatif lemah sebesar $-0,22$, yang mengindikasikan bahwa semakin tinggi tekanan udara, curah hujan cenderung menurun. Adapun kecepatan angin rata-rata

memiliki korelasi negatif sangat lemah sebesar $-0,12$, sehingga dapat dikatakan hampir tidak memiliki hubungan yang signifikan dengan curah hujan pada data tersebut. Di antara keempat variabel, kelembapan udara rata-rata merupakan faktor yang paling berpengaruh terhadap curah hujan dimana interpretasi korelasi ini sesuai dengan penelitian Akoglu (2018).

3.2 Arsitektur dan Konfigurasi Model LSTM

Model yang digunakan dalam penelitian ini adalah LSTM multivariat, yang dirancang untuk memprediksi curah hujan dengan memanfaatkan beberapa variabel cuaca sebagai masukan. Arsitektur model disusun untuk menangkap pola ketergantungan temporal pada data deret waktu, dengan konfigurasi parameter dan *hyperparameter* yang ditentukan melalui proses eksperimen.

Tabel 2. Arsitektur Model LSTM

Parameter	Nilai/Uraian
Input	4
Output	1
Loocbak	7
Layer	2
Fungsi Aktivasi	Sigmoid
Optimizer	Adam
Neuron	64-32
Epoch	50, 100, 200
Batch Size	16, 32

Penelitian ini menggunakan arsitektur model LSTM empat variabel input dan menghasilkan satu nilai output berupa prediksi curah hujan. Arsitektur model terdiri dari dua lapisan LSTM dengan jumlah *neuron* masing-masing 64 dan 32 unit, yang bertujuan untuk menangkap pola temporal yang kompleks. Fungsi aktivasi *sigmoid* digunakan untuk mengatur aliran informasi pada sel LSTM, sedangkan *optimizer* Adam diterapkan untuk meningkatkan stabilitas dan kecepatan konvergensi selama proses pelatihan. Pelatihan model dilakukan dengan variasi epoch 50, 100, dan 200, serta batch size 16 dan 32.

3.3 Evaluasi Kinerja Model LSTM Berdasarkan Variasi Epoch dan Batch Size

Hasil pengujian model dengan berbagai kombinasi *epoch* dan *batch size* disajikan pada Tabel 3. Berdasarkan hasil tersebut, terlihat bahwa variasi epoch dan batch size memberikan pengaruh terhadap kinerja model LSTM dalam memprediksi curah hujan. Nilai MAE dan

RMSE menunjukkan fluktuasi pada setiap konfigurasi, yang mencerminkan perbedaan kemampuan model dalam menangkap pola data.

Tabel 3. Percobaan Kombinasi *Epoch* Dan *Batchsize*

Epoch	Batch size	Data Training	Data Testin	MAE	RMS E
50	16	1453	364	5,139	8,259
	32	1453	364	5,221	8,363
100	16	1453	364	4,020	7,915
	32	1453	364	4,993	8,135
200	16	1453	364	4,620	8,844
	32	1453	364	5,162	8,877

Konfigurasi dengan *epoch* 100 dan batch size 16 menghasilkan nilai MAE terendah, yaitu sebesar 4,020 mm, yang menunjukkan bahwa rata-rata kesalahan prediksi curah hujan paling kecil dan lebih stabil dibandingkan konfigurasi lainnya. Mengingat karakteristik data curah hujan yang bersifat fluktuatif dan mengandung nilai ekstrem, MAE dinilai lebih representatif dalam mengevaluasi kinerja model dibandingkan RMSE yang lebih sensitif terhadap *outlier*.

3.4 Analisis Proses Pelatihan Model

Untuk mengamati proses pembelajaran model LSTM serta kestabilan kinerjanya selama pelatihan, ditampilkan grafik *training loss* dan *validation loss* menggunakan *mean squared error* (MSE) pada setiap *epoch*, sebagaimana ditunjukkan pada Gambar 5.



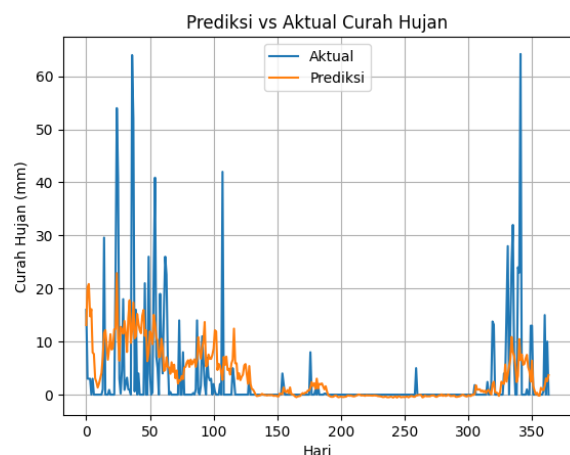
Gambar 5. Grafik *Training* dan *Validation Loss*

Grafik tersebut menunjukkan bahwa nilai *training loss* dan *validation loss* mengalami penurunan dari tahap awal pelatihan hingga akhir, kemudian cenderung stabil seiring bertambahnya jumlah *epoch*. Kedua kurva menunjukkan pola yang relatif berdekatan tanpa perbedaan yang sangat kecil, yang

mengindikasikan bahwa model LSTM mampu melakukan generalisasi dengan baik terhadap data pengujian dan tidak ditemukannya peningkatan *validation loss* secara signifikan pada akhir pelatihan menunjukkan bahwa model tidak mengalami *overfitting*.

3.5 Analisis Hasil Prediksi Curah Hujan

Analisis hasil prediksi dilakukan dengan membandingkan nilai curah hujan aktual dan hasil prediksi model LSTM multivariat pada data uji, sebagaimana ditampilkan pada Gambar 6. Visualisasi ini bertujuan untuk menilai kemampuan model dalam mengikuti pola temporal curah hujan harian.



Gambar 6. Aktual vs Prediksi Data *Testing* Curah Hujan

Berdasarkan Gambar 6, hasil prediksi model LSTM mampu mengikuti pola umum curah hujan aktual, terutama pada periode dengan intensitas hujan rendah hingga sedang. Namun, pada beberapa kejadian hujan dengan intensitas tinggi, model cenderung menghasilkan nilai prediksi yang lebih rendah dibandingkan data aktual. Hal ini menunjukkan bahwa meskipun model mampu menangkap tren dan pola temporal dengan baik, masih terdapat keterbatasan dalam memprediksi kejadian hujan ekstrem. Temuan ini sejalan dengan hasil evaluasi menggunakan MAE dan RMSE, di mana kesalahan prediksi dipengaruhi oleh keberadaan nilai ekstrem pada data curah hujan.

4. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa metode LSTM multivariat efektif digunakan untuk memprediksi curah hujan harian di Kota Mataram dengan memanfaatkan empat variabel cuaca sebagai input. Tahapan praproses data

serta pembagian data 80% data *training* dan 20% data *testing* berperan penting dalam menghasilkan model yang stabil. Hasil evaluasi menggunakan MAE dan RMSE menunjukkan bahwa konfigurasi *epoch* 100 dan *batch size* 16 memberikan kinerja terbaik dengan nilai MAE sebesar 4,020 mm dan RMSE sebesar 7,915 mm, yang mencerminkan kesalahan prediksi rata-rata yang kecil dan stabil. Grafik *training* dan *validation loss* mengindikasikan bahwa model tidak mengalami *overfitting* dan mampu melakukan generalisasi dengan baik. Perbandingan antara curah hujan aktual dan hasil prediksi menunjukkan bahwa model mampu mengikuti pola curah hujan harian, terutama pada intensitas hujan rendah hingga sedang, meskipun masih memiliki keterbatasan dalam memprediksi kejadian hujan ekstrem. Secara keseluruhan, model LSTM yang dikembangkan memiliki potensi untuk digunakan sebagai pendekatan prediksi curah hujan harian.

Penelitian selanjutnya disarankan untuk meningkatkan kinerja model LSTM melalui optimasi hiperparameter secara lebih sistematis, seperti variasi jumlah *neuron*, *layer*, *learning rate*, *batch size*, dan *epoch*. Penggunaan metode tuning otomatis seperti *grid search*, *random search*, atau *Bayesian optimization* dapat membantu menemukan konfigurasi optimal secara efisien. Selain itu, penerapan teknik regularisasi seperti *dropout* dan *early stopping* serta penyesuaian parameter pada *optimizer* Adam juga berpotensi meningkatkan akurasi dan stabilitas model, terutama dalam memprediksi kejadian hujan ekstrem.

DAFTAR PUSTAKA

- Akoglu, H. (2018). User's guide to correlation coefficients. *Turkish Journal of Emergency Medicine*, 18(3), 91–93. <https://doi.org/10.1016/j.tjem.2018.08.001>
- Ashari, Y., & Suhendar, A. 2024. Implementasi algoritma long short-term memory (LSTM) untuk memprediksi harga beras di Jawa Tengah berdasarkan cuaca. *Djtechno: Jurnal Teknologi Informasi*, 5(3), 624–636. <https://doi.org/10.46576/djtechno.v5i3.5136>
- Hidayatullah, S., & Cherid, A. 2023. Prediksi temperatur cuaca di negara Norwegia menggunakan metode LSTM. *Simkom*, 8(2), 187–198. <https://doi.org/10.51717/simkom.v8i2.192>
- Kirono, D. G. C., Butler, J. R. A., McGregor, J. L., Ripaldi, A., Katzfey, J., & Nguyen, K. (2016). Historical and future seasonal rainfall variability in Nusa Tenggara Barat Province, Indonesia: Implications for the agriculture and water sectors. *Climate Risk Management*, 12, 45–58. <https://doi.org/10.1016/j.crm.2015.12.001>
- Merdiansah, R., Wulandari, K., Hasibuan, M., & Umaidah, Y. 2024. Perbandingan kinerja model RNN, LSTM, dan BLSTM dalam memprediksi jumlah gempa bulanan di Indonesia. *Jurnal Penelitian Rumpun Ilmu Teknik*, 3(1), 262–277. <https://doi.org/10.55606/juprit.v3i1.3466>
- Muflih, G. Z., Sunardi, S., & Yudhana, A. 2019. Jaringan saraf tiruan backpropagation untuk prediksi curah hujan di wilayah Kabupaten Wonosobo. *MUST: Journal of Mathematics Education, Science and Technology*, 4(1), 45. <https://doi.org/10.30651/must.v4i1.2670>
- Mukid, M. A., & Sugito. 2013. Model prediksi curah hujan dengan pendekatan regresi proses Gaussian. *Media Statistika*, 6(2), 113–122.
- Musfiroh, M., Novitasari, D. C. R., Intan, P. K., & Wisnawa, G. G. 2023. Penerapan metode principal component analysis (PCA) dan long short-term memory (LSTM) dalam memprediksi curah hujan harian. *Building of Informatics, Technology and Science*, 5(1), 1–11. <https://doi.org/10.47065/bits.v5i1.3114>
- Pranolo, A., Setyaputri, F., Paramarta, A., Triono, A., Fadhilla, A., Akbari, A., Utama, A., Wibawa, A., & Uriu, W. (2024). Enhanced Multivariate Time Series Analysis Using LSTM: A Comparative Study of Min-Max and Z-Score Normalization Techniques. *ILKOM Jurnal Ilmiah*, 16(2), 210-220. <https://doi.org/10.33096/ilkom.v16i2.2333.210-220>
- Rizki, M., Basuki, S., & Azhar, Y. (2024). Implementasi Deep Learning Menggunakan Arsitektur Long Short-Term Memory (LSTM) Untuk Prediksi Curah Hujan Kota Malang. *Jurnal Repositor*, 2(3). <https://doi.org/10.22219/repositor.v2i3.30499>
- Saputra, B. D., Hiryanto, L., & Handhayani, T. 2023. Prediksi curah hujan di Kabupaten

- Badung, Bali menggunakan metode long short-term memory. *Jurnal Ilmu Komputer dan Sistem Informasi*, 11(2). <https://doi.org/10.24912/jiksi.v11i2.26002>
- Wanzhen Wang, Sze Song Ngu, Miaomiao Xin, Rong Liu, Qian Wang, Man Qiu, & Shengqun Zhang. (2024). Tool Wear Prediction Based on Adaptive Feature and Temporal Attention with Long Short-Term Memory Model. *International Journal of Engineering and Technology Innovation*, 14(3), 271–284. <https://doi.org/10.46604/ijeti.2024.13387>
- Wiranda, L., & Sadikin, M. 2019. Penerapan long short-term memory pada data time series untuk memprediksi penjualan produk PT. Metiska Farma. *Jurnal Nasional Pendidikan Teknik Informatika*, 8(3), 184–196.
- Yasin, H. M., & Khorsheed, A. K. 2025. Automated Data Cleaning in Large Databases Using Machine Learning Methods. *Asian Journal of Research in Computer Science*, 18(5), 364–386. <https://doi.org/10.9734/ajrcos/2025/v18i566>