J. Ris. & Ap. Mat. Vol. 10 No. 2 (2026) pp. 320-332
Jurnal Riset dan Aplikasi Matematika (JRAM)
e-ISSN: 2581-0154
DOI: doi.org/10.26740/jram.v10n2.p320-332

PERBANDINGAN METODE SARIMA DAN LSTM DALAM PERAMALAN CURAH HUJAN PER JAM DENGAN KARAKTERISTIK *ZERO-INFLATED* DI SURABAYA

ARTANTI INDRASETIANINGSIH, FENNY FITRIANI, HANI BRILIANTI ROCHMANTO*, ROBIATUL ADAWIYAH, DIVA APRILIA TRISHA UTAMI, LAURA SEKAR FARAMAYSTY, DAN MARIA KRISTINA LUSIA GEONG

Program Studi S1 Statistika, Universitas PGRI Adi Buana Surabaya, Surabaya, Indonesia

*Penulis Korespondensi: rochmantohani@unipasby.ac.id

ABSTRAK

Peramalan curah hujan per jam memiliki tantangan karena data cenderung memiliki pola yang kompleks dan didominasi oleh observasi bernilai nol (*zero-inflated*). Kondisi tersebut dapat memengaruhi kinerja metode peramalan, terutama dalam merepresentasikan periode tanpa hujan dan intensitas ketika hujan terjadi. Penelitian ini bertujuan membandingkan kinerja *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan *Long Short-Term Memory* (LSTM) dalam meramalkan curah hujan per jam di Kota Surabaya. Data yang digunakan terdiri atas 16.080 observasi curah hujan per jam periode Januari 2024 hingga Oktober 2025 yang dibagi secara kronologis menjadi 80% data latih dan 20% data *testing*. Model SARIMA terbaik yang diperoleh adalah SARIMA$(1,1,2)(1,0,1)_{24}$, sedangkan LSTM dibangun menggunakan *lookback* 24 jam dengan 50 unit LSTM. Kinerja model dievaluasi menggunakan RMSE, MAE, dan MASE secara keseluruhan serta RMSE dan MAE secara terpisah pada periode kering dan hujan. Hasil penelitian menunjukkan bahwa LSTM menghasilkan RMSE keseluruhan yang lebih rendah, yaitu 0,2789 dibandingkan SARIMA sebesar 0,3028, sedangkan SARIMA menghasilkan MAE dan MASE yang lebih rendah. Pada periode hujan, LSTM mampu menurunkan RMSE dan MAE masing-masing sebesar 41,28% dan 38,99% dibandingkan SARIMA, sementara SARIMA memberikan kinerja yang lebih baik pada periode kering. Hasil ini menunjukkan bahwa SARIMA lebih efektif dalam merepresentasikan periode tanpa hujan, sedangkan LSTM lebih mampu menangkap variasi intensitas ketika hujan terjadi.
Kata Kunci: curah hujan, LSTM, peramalan, SARIMA, *zero-inflated*

ABSTRACT

Hourly rainfall forecasting presents a particular challenge because rainfall time series tend to exhibit complex patterns and contain a high proportion of zero observations (zero-inflated). This characteristic may affect forecasting performance, particularly in representing dry periods and rainfall intensity during rain events. This study aims to compare the performance of Seasonal Autoregressive Integrated Moving Average (SARIMA) and Long Short-Term Memory (LSTM) for hourly rainfall forecasting in Surabaya, Indonesia. The dataset consists of 16,080 hourly rainfall observations from January 2024 to October 2025, chronologically divided into 80% training data and 20% testing data. The selected SARIMA model was SARIMA$(1,1,2)(1,0,1)_{24}$*, while the LSTM model employed a 24-hour lookback window with 50 LSTM units. Model performance was evaluated using RMSE, MAE, and MASE for the entire testing period, while RMSE and MAE were also evaluated separately for dry and rainy periods. The results show that LSTM achieved a lower overall RMSE of 0.2789 compared with 0.3028 for SARIMA, whereas SARIMA produced lower overall MAE and MASE values. During rainy periods,*

2020 *Mathematics Subject Classification*: 62M20, 62M10, 62M45
Diterima: 26-09-2026, direvisi: 18-10-2026, dimuat: 20-10-2026

LSTM reduced RMSE and MAE by 41.28% and 38.99%, respectively, compared with SARIMA, while SARIMA performed better during dry periods. These findings indicate that SARIMA is more effective in representing dry periods, whereas LSTM is more capable of capturing variations in rainfall intensity during rain events.
Keywords: *forecasting, hourly rainfall, LSTM, SARIMA, zero-inflated*

1. Pendahuluan

Curah hujan merupakan salah satu unsur meteorologi yang memiliki tingkat variabilitas tinggi, baik secara temporal maupun spasial. Informasi mengenai pola dan intensitas curah hujan memiliki peran penting dalam berbagai bidang, seperti pengelolaan sumber daya air, mitigasi risiko banjir, pertanian, transportasi, serta perencanaan wilayah perkotaan [1]. Pada wilayah perkotaan dengan kepadatan penduduk dan aktivitas yang tinggi seperti Kota Surabaya, perubahan intensitas curah hujan dalam waktu relatif singkat dapat memberikan dampak yang signifikan terhadap aktivitas masyarakat dan sistem drainase perkotaan [2]. Oleh karena itu, diperlukan peramalan kajian pengembangan metode peramalan yang mampu menggambarkan dinamika curah hujan dalam jangka pendek.

Namun, karakteristik data curah hujan di daerah tropis seperti Surabaya sering kali menunjukkan tingkat variabilitas temporal yang tinggi, distribusi data yang tidak normal, serta mengandung banyak nilai nol (*zero-inflation*) akibat periode ketika tidak terjadi hujan. Karakteristik tersebut disebabkan karena dalam periode waktu tertentu, terutama di musim kemarau, curah hujan dapat bernilai nol, sedangkan pada musim penghujan nilainya dapat meningkat tajam [3]. Tantangan tersebut menjadi lebih kompleks pada data dengan resolusi tinggi seperti curah hujan per jam karena periode tanpa hujan dapat mendominasi deret waktu, sedangkan kejadian hujan muncul relatif lebih jarang dengan intensitas yang sangat bervariasi [4]. Sehingga, evaluasi model yang hanya didasarkan pada ukuran kesalahan secara keseluruhan berpotensi didominasi oleh periode tanpa hujan dan belum tentu menggambarkan kemampuan model ketika kejadian hujan benar-benar berlangsung.

Salah satu pendekatan statistik yang banyak digunakan untuk pemodelan dan peramalan deret waktu adalah *Seasonal Autoregressive Integrated Moving Average* (SARIMA). Model SARIMA merupakan pengembangan ARIMA yang mengakomodasi komponen autoregresif, *moving average*, *differencing*, serta pola musiman sehingga sesuai untuk deret waktu yang menunjukkan dependensi temporal dan periodisitas tertentu [5]. Beberapa penelitian telah menerapkan SARIMA dalam peramalan curah hujan dan menunjukkan bahwa model tersebut mampu memberikan hasil yang kompetitif ketika pola temporal dan musiman pada data dapat direpresentasikan melalui hubungan linier [6], [7], [8]. Meskipun demikian, asumsi hubungan linier dan struktur model yang telah ditentukan dapat membatasi kemampuan SARIMA dalam merepresentasikan dinamika curah hujan yang kompleks, terutama ketika data mengandung pola nonlinier, nilai ekstrem, serta proporsi nilai nol yang tinggi [9].

Perkembangan *deep learning* menawarkan pendekatan alternatif melalui *Long Short-Term Memory* (LSTM) untuk mengatasi keterbatasan tersebut. Struktur *memory cell* dan mekanisme *gating* pada LSTM memungkinkan informasi relevan dari observasi sebelumnya dipertahankan sehingga model mampu mempelajari hubungan temporal dan nonlinier tanpa harus menentukan bentuk hubungan tersebut secara eksplisit [10]. LSTM telah banyak diterapkan dalam peramalan variabel hidrologi dan meteorologi, termasuk curah hujan, dan pada sejumlah penelitian menunjukkan performa prediksi yang lebih baik dibandingkan pendekatan deret waktu konvensional [11]. Sejumlah studi juga telah membandingkan ARIMA/SARIMA dengan LSTM dan menunjukkan bahwa keunggulan masing-masing metode dapat berbeda bergantung pada karakteristik data, horizon peramalan, dan ukuran evaluasi yang digunakan

[12], [13], [14]. Namun, beberapa penelitian tersebut belum menggambarkan performa model secara objektif pada data curah hujan dengan karakteristik nilai nol yang tinggi.

Untuk mengatasi kesenjangan tersebut, penelitian ini bertujuan untuk membandingkan performa model SARIMA dan LSTM dalam meramalkan curah hujan per jam dengan karakteristik *zero-inflated* di Kota Surabaya. Kontribusi dalam penelitian ini berfokus pada evaluasi performa masing-masing metode yang diukur berdasarkan nilai *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Scaled Error* (MASE) dengan *seasonal naive* periode 24 jam sebagai tolok ukur. Evaluasi model dilakukan secara menyeluruh untuk membandingkan tingkat kesalahan kedua metode. Selain itu, evaluasi juga dilakukan secara terpisah antara periode hujan dan periode tidak hujan untuk mengidentifikasi perbedaan karakteristik SARIMA dan LSTM saat meramalkan periode tanpa hujan dan periode hujan. Sehingga, keunggulan masing-masing model dapat ditelusuri pada kondisi yang berbeda.

2. Tinjauan Pustaka

2.1. *Seasonal Autoregressive Integrated Moving Average* (SARIMA)

SARIMA merupakan pengembangan model ARIMA yang mengakomodasi pola musiman pada suatu deret waktu. Secara umum, model SARIMA dapat dinyatakan sebagai SARIMA $(p,d,q)(P,D,Q)_s$, dengan p, d, dan q masing-masing menunjukkan orde *autoregressive*, *differencing*, dan *moving average* non-musiman. Sedangkan P, D, dan Q menunjukkan orde komponen musiman, serta s merupakan panjang periode musiman [5]. Bentuk umum model dapat dituliskan sebagai berikut:

$$\Phi_P(B^s)\phi_p(B)(1-B)^d(1-B^s)^D Y_t = \Theta_Q(B^s)\theta_q(B)\varepsilon_t \quad (1)$$

dengan B merupakan operator *backshift*, $\phi_p(B)$ dan $\theta_q(B)$ masing-masing merupakan polinomial AR dan MA non-musiman, sedangkan $\Phi_P(B^s)$ dan $\Theta_Q(B^s)$ merupakan polinomial AR dan MA musiman.

Pembentukan model diawali dengan identifikasi autokorelasi melalui plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Selanjutnya dilakukan pengujian stasioneritas data *training* menggunakan *Augmented Dickey-Fuller* (ADF). Berdasarkan hasil pengujian, *differencing* orde pertama dilakukan untuk memperoleh deret yang stasioner sehingga digunakan $d = 1$. Beberapa kombinasi orde SARIMA kemudian diestimasi dan dibandingkan menggunakan *Akaike Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC), dengan nilai yang lebih kecil menunjukkan model yang lebih baik dengan mempertimbangkan kesesuaian model dan kompleksitas parameter [8].

2.2. *Long Short-Term Memory* (LSTM)

LSTM merupakan pengembangan *Recurrent Neural Network* (RNN) yang dirancang untuk mempelajari dependensi temporal pada data sekuensial serta mengatasi keterbatasan RNN konvensional dalam mempertahankan informasi jangka panjang. Mekanisme LSTM terdiri atas *forget gate*, *input gate*, *output gate*, dan *cell state* yang mengendalikan informasi yang dipertahankan, diperbarui, dan diteruskan pada setiap langkah waktu [10]. Karakteristik tersebut memungkinkan LSTM mempelajari hubungan nonlinier pada deret waktu tanpa menentukan struktur hubungan antarobservasi secara eksplisit.

Pada setiap langkah waktu k di dalam jendela masukan (*sliding window*), LSTM menghitung tiga gerbang dan satu kandidat *cell state* berdasarkan vektor input x_k dan *hidden state* sebelumnya (h_{k-1}). *Forget gate* (f_k) menentukan bagian *cell state* sebelumnya yang dipertahankan, sedangkan *input gate* (i_k) menentukan bagian informasi baru yang ditambahkan ke dalam sel. Selanjutnya *output gate* (o_k) menentukan bagian *cell state* yang diteruskan sebagai *hidden state*. Komponen-komponen tersebut dirumuskan sebagai berikut [10], [15]:

$$f_k = \sigma(W_f x_k + U_f h_{k-1} + b_f) \quad (2)$$

$$i_k = \sigma(W_i x_k + U_i h_{k-1} + b_i) \quad (3)$$

$$\tilde{c}_k = \tanh(W_c x_k + U_c h_{k-1} + b_c) \quad (4)$$

$$c_k = f_k \odot c_{k-1} + i_k \odot \tilde{c}_k \quad (5)$$

$$o_k = \sigma(W_o x_k + U_o h_{k-1} + b_o) \quad (6)$$

$$h_k = o_k \odot \tanh(c_k) \quad (7)$$

dengan W_f, W_i, W_c, W_o merupakan matriks bobot masukan dan U_f, U_i, U_c, U_o merupakan matriks bobot untuk *hidden state*. Simbol b_f, b_i, b_c, b_o masing-masing menyatakan vektor bias. Fungsi $\sigma(\cdot)$ merupakan fungsi aktivasi sigmoid, $\tanh(\cdot)$ merupakan fungsi tangen hiperbolik, dan $\odot$ menunjukkan perkalian elemen demi elemen. Selanjutnya, c_k menyatakan keadaan sel (*cell state*), $\tilde{c}_k$ merupakan kandidat *cell state*, dan h_k merupakan *hidden state* pada waktu ke-k.

Pada penelitian ini, panjang *lookback* pada *sliding window* ditetapkan sebesar 24 jam sehingga k= 1,2, ...,24. Setiap input x_k merupakan nilai curah hujan ternormalisasi pada jam ke-$(t - 25 + k)$ yang digunakan untuk meramalkan curah hujan pada jam ke-t. *Hidden state* pada langkah terakhir (h_{24}) diteruskan ke lapisan *Dense* satu neuron untuk menghasilkan ramalan curah hujan yang dinyatakan sebagai berikut [15]:

$$\hat{Y}_t^* = W_d h_{24} + b_d \quad (8)$$

dengan W_d dan b_d masing-masing merupakan bobot dan bias lapisan *Dense*, dan $\hat{Y}_t^*$ merupakan ramalan pada skala ternormalisasi menggunakan *Min-Max Scaling* ke dalam rentang 0–1 dengan rumus sebagai berikut [16]:

$$Y_t = \frac{Y_t - Y_{\min}}{Y_{\max} - Y_{\min}} \quad (9)$$

dengan $Y_{\min}$ dan $Y_{\max}$ masing-masing merupakan nilai minimum dan maksimum data *training*. Hasil ramalan tersebut selanjutnya dikembalikan ke skala pengukuran awal melalui proses *inverse transformation* sehingga dinyatakan dalam satuan milimeter (mm).

Selanjutnya, data dibentuk menjadi pasangan *input-output* menggunakan pendekatan *sliding window* dengan panjang *lookback* 24 jam. Artinya, 24 curah hujan sebelumnya digunakan sebagai input untuk memprediksi curah hujan pada jam ke-t. Arsitektur LSTM yang digunakan terdiri atas satu lapisan LSTM dengan 50 unit dan satu lapisan *Dense* dengan satu neuron sebagai keluaran prediksi curah hujan. Model dioptimasi menggunakan algoritma Adam dengan *loss function Mean Squared Error* (MSE). Proses *training* dilakukan dengan maksimum 100 *epoch*, ukuran *batch* sebesar 32, dan tanpa pengacakan urutan observasi. Mekanisme *early stopping* dengan *patience* sebesar 10 *epoch* diterapkan untuk menghentikan proses *training* ketika *validation loss* tidak lagi mengalami perbaikan serta mengembalikan bobot model pada *epoch* dengan nilai *validation loss* terbaik.

2.3. Evaluasi Kinerja Model

Evaluasi kinerja SARIMA dan LSTM dilakukan pada 3.216 observasi data *testing* yang sama sehingga perbandingan kedua pendekatan dilakukan pada periode peramalan yang identik. Ukuran evaluasi utama yang digunakan adalah *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Scaled Error* (MASE). RMSE memberikan penalti yang lebih besar terhadap kesalahan peramalan dengan *magnitude* besar, sedangkan MAE mengukur rata-rata kesalahan absolut tanpa memberikan bobot tambahan terhadap *error* yang besar [17]. Kedua ukuran tersebut masing-masing dirumuskan sebagai berikut:

$$\text{RMSE} = \sqrt{\frac{1}{n}\sum_{t=1}^{n}\left(Y_t - \hat{Y}_t\right)^2} \tag{10}$$

dan

$$\text{MAE} = \frac{1}{n}\sum_{t=1}^{n}\left|Y_t - \hat{Y}_t\right| \tag{11}$$

dengan Y_t merupakan nilai curah hujan aktual, $\hat{Y}_t$ merupakan hasil peramalan, dan n merupakan jumlah observasi data *testing*.

MASE digunakan sebagai ukuran kesalahan berskala yang membandingkan MAE model dengan kesalahan metode *naive* [18]. Penelitian ini menggunakan *seasonal naive* dengan periode 24 jam sebagai pembanding karena data memiliki struktur harian. MASE dihitung menggunakan rumus berikut [19]:

$$\text{MASE} = \frac{\frac{1}{n}\sum_{t=1}^{n}\left|Y_t - \hat{Y}_t\right|}{\frac{1}{T-24}\sum_{t=1}^{T}\left|Y_t - \hat{Y}_t\right|} \tag{12}$$

dengan T menunjukkan jumlah observasi pada data latih. Nilai MASE kurang dari satu menunjukkan bahwa model menghasilkan kesalahan absolut yang lebih kecil dibandingkan metode *seasonal naive* 24 jam.

Selain evaluasi agregat, RMSE dan MAE dihitung secara terpisah berdasarkan kondisi curah hujan aktual. Periode kering didefinisikan sebagai observasi dengan $Y_t = 0$, sedangkan periode hujan didefinisikan sebagai observasi dengan $Y_t > 0$. Evaluasi terpisah tersebut dilakukan karena dominasi nilai nol pada data dapat menyebabkan ukuran kesalahan keseluruhan lebih banyak dipengaruhi oleh kemampuan model dalam meramalkan periode tanpa hujan. Dengan membandingkan kinerja pada kedua kondisi, penelitian ini dapat mengevaluasi kemampuan SARIMA dan LSTM dalam merepresentasikan kondisi tanpa hujan sekaligus memprediksi intensitas curah hujan ketika kejadian hujan berlangsung.

2.4. Sumber Data dan Variabel Penelitian

Penelitian ini menggunakan data sekunder berupa curah hujan per jam dalam satuan milimeter (mm) di Kota Surabaya dengan periode pengamatan mulai 1 Januari 2024 hingga 31 Oktober 2025. Keseluruhan periode pengamatan menghasilkan sebanyak 16.080 observasi. Variabel yang digunakan dalam pemodelan dinotasikan sebagai Y_t, yaitu besarnya curah hujan pada jam ke-t. Selanjutnya, data dibagi menjadi data *training* dan data *testing* dengan proporsi 80:20 tanpa pengacakan. Sebanyak 12.864 (80%) observasi pertama digunakan sebagai data *training*, sedangkan 3.216 (20%) observasi berikutnya digunakan sebagai data *testing*. Pada pemodelan SARIMA, data *training* digunakan untuk mengidentifikasi dan mengestimasi parameter model, sedangkan pada LSTM data *training* digunakan untuk melatih jaringan saraf dalam mempelajari pola temporal curah hujan berdasarkan 24 observasi sebelumnya (*lookback* 24 jam) untuk memprediksi curah hujan pada jam berikutnya. Proses pelatihan dilakukan dengan mengoptimalkan bobot dan bias jaringan menggunakan optimizer Adam serta fungsi kerugian *Mean Squared Error* (MSE).

2.5. Tahapan Analisis

Tahapan penelitian diawali dengan eksplorasi karakteristik data melalui visualisasi deret waktu dan identifikasi proporsi observasi curah hujan bernilai nol (periode tidak hujan) dan lebih besar dari nol (periode hujan). Pemodelan dilakukan menggunakan dua pendekatan, yaitu *Seasonal Autoregressive Integrated Moving Average* (SARIMA) sebagai pendekatan statistik deret waktu dan *Long Short-Term Memory* (LSTM) sebagai pendekatan *deep learning*. Masing-

masing model dibentuk menggunakan data *training* dan menghasilkan ramalan untuk seluruh periode data *testing* yang sama. Hasil peramalan selanjutnya dibandingkan berdasarkan ukuran kesalahan secara keseluruhan maupun berdasarkan kondisi curah hujan aktual, yaitu periode kering ($Y_t = 0$) dan periode hujan ($Y_t > 0$). Alur keseluruhan penelitian disajikan pada Gambar 1.

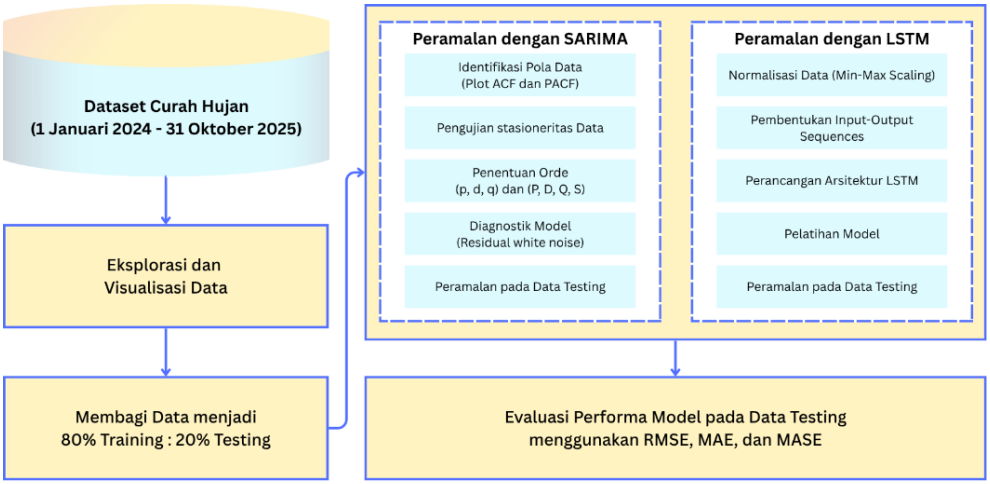

Gambar 1. Diagram Alir Peramalan Curah Hujan dengan SARIMA dan LSTM

3. Hasil dan Pembahasan

Data curah hujan per jam di Kota Surabaya selama periode 1 Januari 2024 hingga 31 Oktober 2025 terdiri atas 16.080 observasi. Data curah hujan yang divisualisasikan pada Gambar 2 menunjukkan bahwa curah hujan memiliki pola yang tidak kontinu, dengan periode tanpa hujan yang relatif panjang diselingi oleh kejadian hujan dengan intensitas yang bervariasi. Kondisi tersebut menghasilkan deret waktu dengan konsentrasi observasi pada nilai nol serta sejumlah nilai positif yang tersebar secara tidak merata sepanjang periode pengamatan. Pola tersebut merupakan karakteristik umum data curah hujan beresolusi tinggi, ketika periode tanpa hujan lebih sering ditemukan dibandingkan periode terjadi hujan [9].

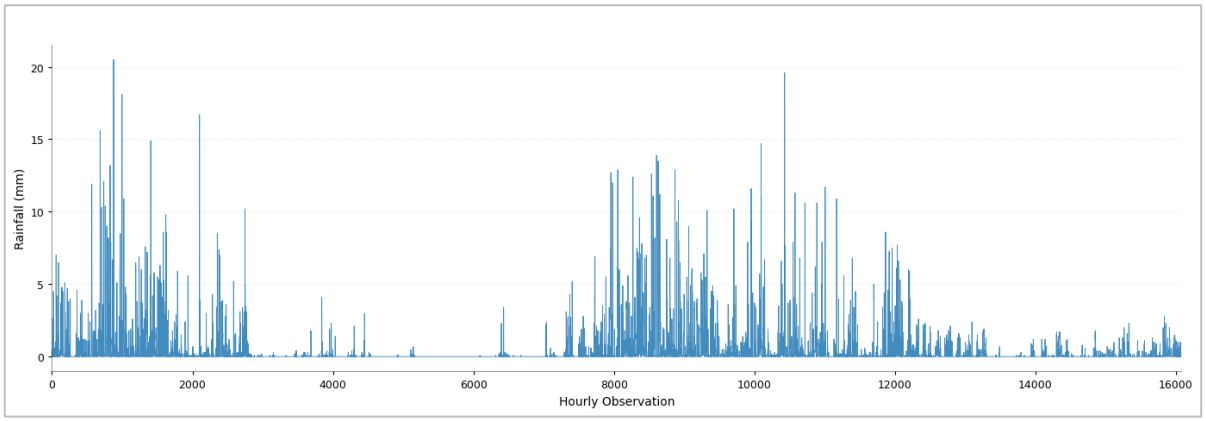

Gambar 2. Visualisasi Curah Hujan di Kota Surabaya (periode 1 Januari 2024 hingga 31 Oktober 2025)

Curah hujan per jam di Kota Surabaya juga menunjukkan adanya karakteristik *zero-inflated*, di mana sebesar 71,42% observasi menunjukkan curah hujan sebesar 0 mm, sedangkan observasi dengan curah hujan lebih besar dari nol memiliki proporsi yang lebih rendah, yaitu sebesar 28,58%. Pada kondisi tersebut, model dapat menghasilkan tingkat kesalahan agregat

yang relatif rendah apabila mampu memprediksi periode tanpa hujan dengan baik. Penelitian ini melakukan peramalan curah hujan per jam menggunakan dua pendekatan, yaitu *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan *Long Short-Term Memory* (LSTM). SARIMA digunakan untuk merepresentasikan struktur dependensi temporal dan pola musiman melalui pendekatan statistik deret waktu, sedangkan LSTM digunakan sebagai pendekatan *deep learning* yang mampu mempelajari pola temporal dan hubungan nonlinier dari data secara sekuensial.

3.1. Peramalan dengan Metode SARIMA

Peramalan dengan metode SARIMA diawali dengan pemeriksaan pola autokorelasi melalui plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) pada Gambar 2. Pemeriksaan dilakukan terhadap data curah hujan untuk memperoleh gambaran awal mengenai dependensi temporal dan pola musiman yang terdapat pada data. Plot ACF menunjukkan autokorelasi yang relatif tinggi pada *lag* awal serta pola peningkatan autokorelasi yang berulang pada *lag* 24, 48, 72, 96, 120, 144, dan 168. Pola berulang pada kelipatan 24 tersebut mengindikasikan adanya dependensi temporal dengan periode harian pada data curah hujan per jam. Sementara itu, plot PACF menunjukkan korelasi parsial yang relatif kuat pada beberapa *lag* awal dan *spike* pada sejumlah *lag* yang berkaitan dengan periode 24 jam. Hasil tersebut mengindikasikan bahwa pemodelan perlu mempertimbangkan komponen non-musiman sekaligus komponen musiman dengan periode $s = 24$.

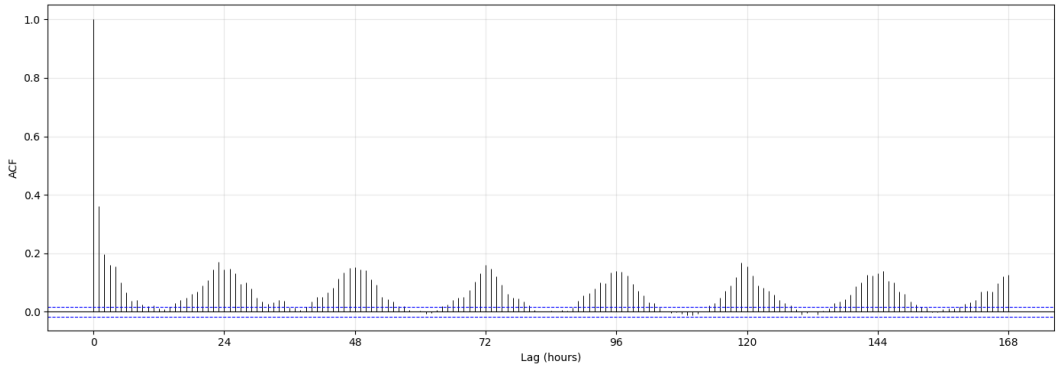

(a) Plot ACF

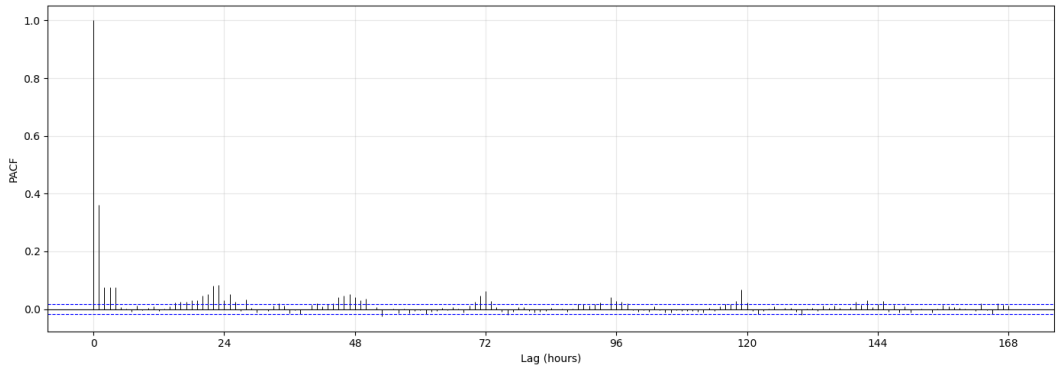

(b) Plot PACF

Gambar 3. Plot ACF dan PACF pada Data Curah Hujan di Kota Surabaya

Berdasarkan plot ACF dan PACF pada Gambar 3, keberadaan autokorelasi yang persisten pada data awal menunjukkan perlunya transformasi melalui proses *differencing* sebelum pembentukan model. Oleh karena itu, dilakukan *first differencing* dengan menghitung selisih antara curah hujan pada waktu ke-t dan satu periode sebelumnya. Setelah proses *differencing*,

dilakukan pengujian stasioneritas data menggunakan uji *Augmented Dickey-Fuller* (ADF) dengan hipotesis sebagai berikut [20]:
H_0: data tidak stasioner
H_1: data stasioner
Hasil pengujian terhadap data setelah *first differencing* menghasilkan statistik ADF sebesar −27,994 dengan *p-value* mendekati 0,000. Nilai *p-value* yang lebih kecil dari taraf signifikansi 5% menyebabkan hipotesis nol ditolak. Artinya, data curah hujan setelah *first differencing* dinyatakan telah memenuhi kondisi stasioner sehingga orde *differencing* nonmusiman ditetapkan sebesar $d = 1$.

Selanjutnya, model SARIMA dibentuk dengan mempertimbangkan komponen AR dan MA dengan periode musiman sebesar 24. Beberapa kombinasi orde non-musiman dan musiman dibentuk dan dievaluasi berdasarkan nilai AIC dan BIC seperti yang ditampilkan pada Tabel 1 berikut:

Tabel 1. Perbandingan Kandidat Model SARIMA

No.	Model	p	d	q	P	D	Q	Nilai AIC	Nilai BIC
1.	SARIMA$(1,1,2)(1,0,1)_{24}$	1	1	2	1	0	1	36.040,57	36.085,33
2.	SARIMA$(1,1,1)(1,0,1)_{24}$	1	1	1	1	0	1	36.055,04	36.092,34
3.	SARIMA$(0,1,2)(1,0,2)_{24}$	0	1	2	1	0	2	36.061,29	36.106,04
4.	SARIMA$(0,1,2)(2,0,1)_{24}$	0	1	2	2	0	1	36.068,11	36.112,86
5.	SARIMA$(0,1,3)(1,0,1)_{24}$	0	1	3	1	0	1	36.071,46	36.116,22
6.	SARIMA$(0,1,2)(1,0,1)_{24}$	0	1	2	1	0	1	36.136,65	36.173,95
7.	SARIMA$(0,1,2)(0,0,1)_{24}$	0	1	2	0	0	1	36.550,88	36.580,72
8.	SARIMA$(0,1,2)(1,0,0)_{24}$	0	1	2	1	0	0	36.555,46	36.585,30
9.	SARIMA$(0,1,1)(1,0,1)_{24}$	0	1	1	1	0	1	36.874,78	36.904,62
10.	SARIMA$(0,1,1)(1,0,0)_{24}$	0	1	1	1	0	0	37.550,52	37.572,90

Berdasarkan Tabel 1, model SARIMA$(1,1,2)(1,0,1)_{24}$ menghasilkan nilai AIC dan BIC terkecil, masing-masing sebesar 36.040,57 dan 36.085,33. Hasil tersebut menunjukkan bahwa penambahan komponen AR(1) non-musiman memberikan peningkatan performa model. Sehingga, curah hujan selanjutnya diramalkan dengan model SARIMA terbaik, yaitu SARIMA$(1,1,2)(1,0,1)_{24}$.

Tahap selanjutnya adalah melakukan estimasi parameter untuk mengetahui kontribusi masing-masing komponen autoregresif dan *moving average*, baik pada bagian nonmusiman maupun musiman. Hasil estimasi parameter model SARIMA$(1,1,2)(1,0,1)_{24}$ disajikan pada Tabel 2.

Tabel 2. Pengujian Estimasi Parameter Model SARIMA

Parameter	Nilai Estimasi	Std. Error	Statistik Uji Z	*p-value*
AR(1)	0,4254	0,016	26,874	0,001
MA(1)	−1,1573	0,016	−70,610	0,001
MA(2)	0,1655	0,016	10,328	0,001
Seasonal AR(1)	0,9849	0,002	527,081	0,001
Seasonal MA(1)	−0,9573	0,003	−315,361	0,001
σ^2	0,9645	0,002	416,402	0,001

Berdasarkan Tabel 2, seluruh parameter pada model SARIMA$(1,1,2)(1,0,1)_{24}$ memiliki *p-value* kurang dari 0,05 sehingga signifikan secara statistik pada taraf signifikansi 5%.

Parameter AR(1) sebesar 0,4254 menunjukkan adanya hubungan positif antara nilai deret setelah *differencing* pada suatu jam dengan nilai pada satu jam sebelumnya. Sementara itu, parameter MA(1) dan MA(2) masing-masing sebesar −1,1573 dan 0,1655 menunjukkan bahwa *error* peramalan pada periode sebelumnya turut berkontribusi terhadap dinamika curah hujan. Pada komponen musiman, parameter seasonal AR(1) sebesar 0,9849 menunjukkan adanya ketergantungan temporal yang kuat pada periode 24 jam, sejalan dengan pola berulang yang sebelumnya teridentifikasi pada plot ACF. Parameter seasonal MA(1) sebesar −0,9573 juga menunjukkan kontribusi kesalahan pada *lag* musiman 24 jam terhadap nilai deret pada periode berjalan.

Setelah pengujian parameter, dilakukan pemeriksaan diagnostik *residual* untuk mengevaluasi apakah model SARIMA yang terbentuk telah memenuhi asumsi *white noise* dan berdistribusi normal. Pemeriksaan asumsi *white noise* dilakukan menggunakan uji Ljung–Box, sedangkan normalitas *residual* diperiksa menggunakan uji Jarque–Bera. Uji Ljung–Box pada *lag* 24, 48, 72, dan 168 menghasilkan *p-value* kurang dari 0,05. Hasil tersebut menunjukkan bahwa *residual* masih mengandung autokorelasi sehingga belum memenuhi asumsi *white noise*. Uji Jarque–Bera juga menghasilkan *p-value* kurang dari 0,05, sehingga *residual* tidak memenuhi asumsi distribusi normal.

3.2. Peramalan dengan Metode LSTM

Peramalan selanjutnya dilakukan menggunakan metode *Long Short-Term Memory* (LSTM). Berbeda dengan SARIMA yang memerlukan identifikasi orde model berdasarkan pola ACF dan PACF, LSTM mempelajari pola data secara langsung melalui struktur sekuensial. Sebelum proses pemodelan, data curah hujan dibagi menjadi data *training* dan data *testing*. Pertama, data *training* terlebih dahulu dinormalisasi menggunakan metode *Min-Max scaling*. Parameter normalisasi diperoleh dari data *training* dan kemudian diterapkan pada data *testing* untuk menghindari kebocoran informasi (*data leakage*). Selanjutnya, data *training* dibentuk menjadi pasangan input dan target menggunakan pendekatan *sliding window* dengan panjang *lookback* 24 jam. Setiap urutan input terdiri atas 24 observasi curah hujan sebelumnya dan digunakan untuk memprediksi observasi pada jam berikutnya. Arsitektur LSTM terdiri atas satu lapisan LSTM dengan 50 unit dan satu lapisan *Dense* dengan satu neuron sebagai keluaran. Proses pelatihan menggunakan optimizer Adam, *Mean Squared Error* (MSE) sebagai *loss function*, ukuran *batch* 32, dan maksimum 100 *epoch*. Sebanyak 20% bagian akhir dari data *training* digunakan sebagai data validasi secara berurutan, dengan mekanisme *early stopping* berpatokan pada nilai *validation loss* dan *patience* 10 *epoch*.

Perubahan nilai *training loss* dan *validation loss* selama proses pelatihan LSTM ditunjukkan pada Gambar 4.

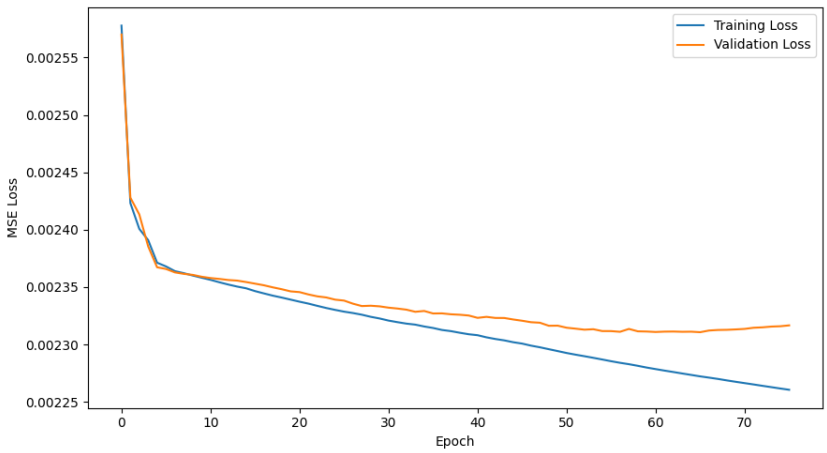

Gambar 4. Plot *Training Loss* dan *Validation Loss* LSTM

Proses pelatihan model dievaluasi berdasarkan perubahan nilai *training loss* dan *validation loss* pada setiap *epoch*. Penggunaan *early stopping* bertujuan untuk memperoleh model pada kondisi ketika *validation loss* mencapai nilai terbaik sekaligus mengurangi risiko *overfitting*. Berdasarkan Gambar 4, nilai *training loss* dan *validation loss* mengalami penurunan selama proses pelatihan hingga mencapai kondisi yang relatif stabil. Proses pelatihan model LSTM berlangsung hingga *epoch* ke-76 dari maksimum 100 *epoch*. Berdasarkan hasil pemantauan *validation loss*, nilai terbaik diperoleh pada *epoch* ke-66, dengan *training loss* sebesar 0,002272 dan *validation loss* sebesar 0,002311. Model dengan bobot pada *epoch* ke-66 kemudian digunakan untuk melakukan peramalan pada data uji. Selanjutnya, hasil prediksi yang masih berada dalam skala normalisasi selanjutnya dikembalikan ke satuan awal menggunakan proses *inverse transformation*, sehingga hasil peramalan dapat dinyatakan kembali dalam satuan milimeter (mm).

3.3. Perbandingan Performa Model SARIMA dan LSTM

Evaluasi dilakukan untuk membandingkan kemampuan model SARIMA dan LSTM dalam meramalkan curah hujan per jam pada data *testing*. Kedua model dievaluasi menggunakan 3.216 observasi yang sama dengan ukuran *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Scaled Error* (MASE). Nilai ukuran evaluasi yang semakin kecil menunjukkan tingkat kesalahan peramalan yang semakin rendah. Hasil evaluasi kedua model disajikan pada Tabel 3.

Tabel 3. Perbandingan Performa SARIMA dan LSTM

Model	RMSE	MAE	MASE
SARIMA	0,3028	**0,1282**	**0,2840**
LSTM	**0,2789**	0,2386	0,5285

Berdasarkan Tabel 3, LSTM menghasilkan nilai RMSE sebesar 0,2789, lebih rendah dibandingkan SARIMA sebesar 0,3028. Hasil tersebut menunjukkan bahwa LSTM memiliki kemampuan yang lebih baik dalam mengurangi kesalahan peramalan dengan magnitudo yang besar. Sebaliknya, SARIMA menghasilkan MAE dan MASE yang lebih rendah, yaitu masing-masing sebesar 0,1282 dan 0,2840, dibandingkan LSTM sebesar 0,2386 dan 0,5285. Nilai MASE kedua model yang kurang dari satu menunjukkan bahwa SARIMA maupun LSTM menghasilkan peramalan yang lebih baik dibandingkan seasonal naive dengan periode 24 jam. Perbedaan hasil antarukuran evaluasi menunjukkan bahwa keunggulan model tidak dapat ditentukan hanya berdasarkan satu ukuran kesalahan.

Perbedaan tersebut berkaitan dengan karakteristik data *testing* yang didominasi oleh observasi tanpa hujan. Dari 3.216 observasi data *testing*, sebanyak 2.578 observasi atau 80,16% memiliki curah hujan sebesar nol, sedangkan 638 observasi atau 19,84% menunjukkan adanya kejadian hujan. Oleh karena itu, evaluasi selanjutnya dilakukan secara terpisah pada periode kering dan periode hujan menggunakan RMSE dan MAE. Hasil evaluasi berdasarkan kondisi curah hujan disajikan pada Tabel 4.

Tabel 4. Perbandingan Performa SARIMA dan LSTM

Kondisi	Ukuran	SARIMA	LSTM
Tidak Hujan ($Y_t = 0$)	RMSE	**0,0634**	0,2428
Tidak Hujan ($Y_t = 0$)	MAE	**0,0453**	0,2277
Hujan ($Y_t > 0$)	RMSE	0,6678	**0,3921**
Hujan ($Y_t > 0$)	MAE	0,4634	**0,2827**

Berdasarkan Tabel 8, SARIMA memberikan hasil yang lebih baik pada periode kering dengan RMSE sebesar 0,0634 dan MAE sebesar 0,0453. Nilai tersebut jauh lebih rendah dibandingkan RMSE dan MAE LSTM yang masing-masing sebesar 0,2428 dan 0,2277. Hal ini menunjukkan bahwa SARIMA lebih mampu menghasilkan prediksi yang mendekati nol ketika tidak terjadi hujan. Dominasi periode kering pada data *testing* juga menjelaskan rendahnya MAE dan MASE SARIMA pada evaluasi keseluruhan.

Sebaliknya, pada periode ketika hujan terjadi, LSTM memberikan kinerja yang lebih baik. LSTM menghasilkan RMSE sebesar 0,3921 dan MAE sebesar 0,2827, sedangkan SARIMA menghasilkan RMSE sebesar 0,6678 dan MAE sebesar 0,4634. Dibandingkan SARIMA, penggunaan LSTM menurunkan RMSE pada periode hujan sekitar 41,28% dan menurunkan MAE sekitar 38,99%. Hasil tersebut menunjukkan bahwa LSTM lebih mampu mengikuti perubahan intensitas curah hujan ketika kejadian hujan berlangsung. Kemampuan ini juga menyebabkan LSTM memperoleh RMSE keseluruhan yang lebih rendah karena RMSE memberikan penalti yang lebih besar terhadap kesalahan dengan magnitudo tinggi.

Perbedaan karakteristik peramalan kedua model juga terlihat pada nilai prediksi yang dihasilkan. SARIMA menghasilkan sebanyak 1.457 atau 45,30% prediksi curah hujan bernilai negatif, sedangkan LSTM hanya menghasilkan 2 atau 0,06% prediksi negatif. Nilai curah hujan negatif tidak memiliki interpretasi secara fisik sehingga hasil tersebut menunjukkan keterbatasan SARIMA dalam menghasilkan prediksi yang sesuai dengan batas alami variabel curah hujan. Meskipun demikian, rendahnya prediksi SARIMA di sekitar nol menyebabkan model tersebut tetap menghasilkan kesalahan yang lebih kecil pada periode kering. Sementara itu, LSTM cenderung menghasilkan prediksi positif pada periode tanpa hujan sehingga meningkatkan MAE pada kondisi kering. Perbandingan data testing aktual dan hasil peramalan dari metode SARIMA dan LSTM disajikan pada Gambar 5.

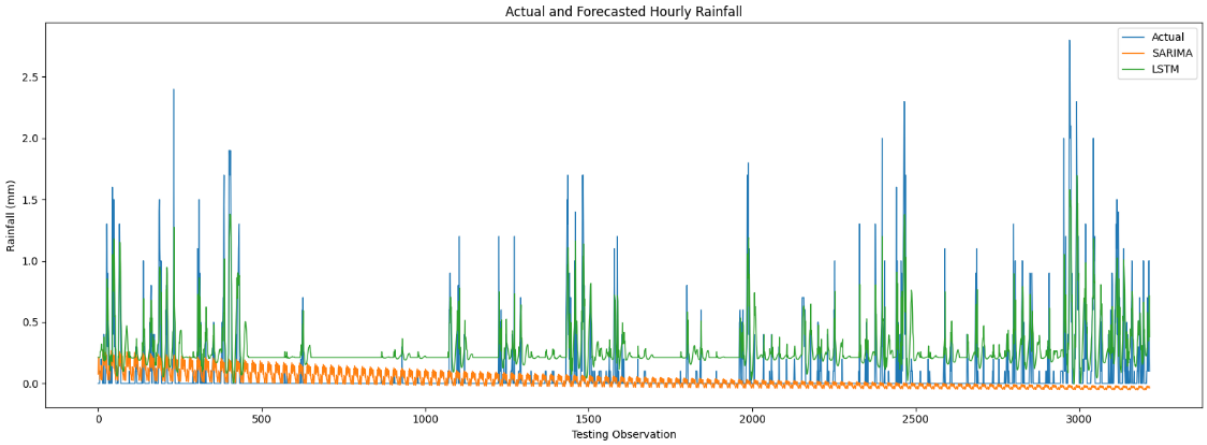

Gambar 5. Perbandingan Data *Testing* Aktual dan Hasil Peramalan SARIMA dan LSTM

4. Kesimpulan

Berdasarkan hasil penelitian, model terbaik yang diperoleh pada pendekatan SARIMA adalah SARIMA$(1,1,2)(1,0,1)_{24}$, sedangkan model LSTM dibentuk menggunakan *lookback* 24 jam dengan 50 unit LSTM. Hasil evaluasi pada 3.216 observasi data *testing* menunjukkan bahwa kedua model memiliki keunggulan yang berbeda dalam meramalkan curah hujan per jam. LSTM menghasilkan nilai RMSE yang lebih rendah daripada SARIMA, yaitu 0,2789 dibandingkan SARIMA sebesar 0,3028. Sedangkan SARIMA menghasilkan nilai MAE dan MASE yang lebih rendah, masing-masing sebesar 0,1282 dan 0,2840 dibandingkan LSTM sebesar 0,2386 dan 0,5285. Evaluasi terpisah berdasarkan kondisi curah hujan menunjukkan bahwa SARIMA lebih baik pada periode kering, sedangkan LSTM lebih baik pada periode hujan dengan penurunan RMSE dan MAE masing-masing sebesar 41,28% dan 38,99%

dibandingkan SARIMA. Selain itu, LSTM hanya menghasilkan 0,06% prediksi negatif, jauh lebih rendah dibandingkan SARIMA sebesar 45,30%. Hasil tersebut menunjukkan bahwa pada data curah hujan per jam dengan karakteristik *zero-inflated*, tidak terdapat satu model yang secara konsisten lebih unggul pada seluruh kondisi. SARIMA lebih efektif dalam merepresentasikan periode tanpa hujan yang mendominasi data, sedangkan LSTM lebih mampu menangkap variasi intensitas ketika hujan terjadi.

Ucapan Terima Kasih

Penulis menyampaikan terima kasih kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) Universitas PGRI Adi Buana Surabaya atas dukungan yang diberikan melalui skema Hibah Riset Inovatif sehingga penelitian ini dapat terlaksana dengan baik.

Daftar Pustaka

[1] Bappenas, *Kebijakan Pembangunan Berketahanan Iklim (PBI)*. Jakarta, Indonesia: Kementerian PPN/Bappenas, 2021.

[2] BPBD, *Kajian Risiko Bencana Nasional Provinsi Jawa Timur 2022–2026*. Jakarta, Indonesia: BNPB, 2021.

[3] M. A. Dinamarca, F. Rojas, C. Ibacache-Quiroga, and K. González-Pizarro, "Modeling Time Series with SARIMAX and Skew-Normal and Zero-Inflated Skew-Normal Errors," *Mathematics*, vol. 13, no. 11, p. 1892, Jun. 2025, doi: 10.3390/math13111892.

[4] I. Yuliyono and A. Supriyanto, "Deep Learning for PM2.5 Prediction under Zero-Inflated Tropical Rainfall: RNN vs GRU," *Edumatic: Jurnal Pendidikan Informatika*, vol. 10, no. 1, pp. 250–259, Apr. 2026, doi: 10.29408/edumatic.v10i1.34418.

[5] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th ed. Hoboken, NJ, USA: John Wiley & Sons, 2015.

[6] M. I. Hakiqi, A. Firmansyah, and R. Arisanti, "Peramalan Curah Hujan di Kota Bandung dengan Metode SARIMA (Seasonal Autoregressive Integrated Moving Average)," *Inferensi*, vol. 1, no. 1, pp. 23–29, Oct. 2023, doi: 10.12962/j27213862.v1i1.19119.

[7] I. Ramli, S. Rusdiana, A. Achmad, Azizah, and M. E. Yolanda, "Forecasting of Rainfall Using Seasonal Autoregressive Integrated Moving Average (SARIMA) Aceh, Indonesia," *Mathematical Modelling of Engineering Problems*, vol. 10, no. 2, p. 501, Apr. 2023, doi: 10.18280/mmep.100216.

[8] H. V. T. Minh et al., "Modelling and predicting annual rainfall over the Vietnamese Mekong Delta (VMD) using SARIMA," *Discover Geoscience*, vol. 2, no. 1, p. 19, Jun. 2024, doi: 10.1007/s44288-024-00018-0.

[9] A. Abbas, T. Ahmad, and I. Ahmad, "Modeling zero-inflated precipitation extremes," *Commun. Stat. Simul. Comput.*, Apr. 2025, doi: 10.1080/03610918.2025.2585398.

[10] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.

[11] D. Sharma, A. K. Shukla, and P. Rattan, "Machine learning techniques for rainfall

prediction: a systematic literature review," *IAES Int. J. Artif. Intell. (IJ-AI)*, vol. 15, no. 4, pp. 3441–3451, Aug. 2026, doi: 10.11591/ijai.v15.i4.pp3441-3451.

[12] A. O. Ayo, P. A. Owolawi, and J. S. Ojo, "Prediction of Time Series Rain-Induced Attenuation Using SARIMA and LSTM Models over Subtropical Climate: A Comparison," *J. Comput. Commun.*, vol. 14, no. 4, pp. 211–237, Apr. 2026, doi: 10.4236/jcc.2026.144011.

[13] N. D. Pramudya, R. Gernowo, and I. Waspada, "Rainfall Prediction at Ahmad Yani Meteorological Station Using Integration ARIMA and LSTM," *Scientific Journal of Informatics*, vol. 13, no. 1, pp. 201–216, Mar. 2026, doi: 10.15294/sji.v13i1.39297.

[14] A. A. Akbar, Y. Darmawan, A. Wibowo, and H. K. Rahmat, "Accuracy Assessment of Monthly Rainfall Predictions using Seasonal ARIMA and Long Short-Term Memory (LSTM)," *Journal of Computer Science and Engineering (JCSE)*, vol. 5, no. 2, pp. 99–114, 2024.

[15] H. Hewamalage, C. Bergmeir, and K. Bandara, "Recurrent Neural Networks for Time Series Forecasting: Current status and future directions," *Int. J. Forecast.*, vol. 37, no. 1, pp. 388–427, Jan. 2021, doi: 10.1016/j.ijforecast.2020.06.008.

[16] Y. O. Ouma, R. Cheruyot, and A. N. Wachera, "Rainfall and runoff time-series trend analysis using LSTM recurrent neural network and wavelet neural network with satellite-based meteorological data: case study of Nzoia hydrologic basin," *Complex Intell. Syst.*, vol. 8, no. 1, pp. 213–236, Apr. 2021, doi: 10.1007/s40747-021-00365-2.

[17] O. A. Ejohwomu et al., "Modelling and Forecasting Temporal PM2.5 Concentration Using Ensemble Machine Learning Methods," *Buildings*, vol. 12, no. 1, p. 46, Jan. 2022, doi: 10.3390/buildings12010046.

[18] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *Int. J. Forecast.*, vol. 22, no. 4, pp. 679–688, Oct. 2006, doi: 10.1016/j.ijforecast.2006.03.001.

[19] R. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 3rd ed. Melbourne, Australia: OTexts, 2021.

[20] L. Shofwatillah, "Peramalan Curah Hujan di Provinsi Sumatera Utara Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA)," *Emerging Statistics and Data Science Journal*, vol. 3, no. 3, pp. 697–710, Oct. 2025, doi: 10.20885/esds.vol3.iss.3.art22.