

Perbandingan Kinerja Model Random Forest dan LSTM dalam Prediksi Curah Hujan Bulanan pada Wilayah Zona Musim di Jawa Tengah

Cahya Sugiarto¹, Yosafat Donni Haryanto^{*2}, Adnan Dendy Mardika³, Purwanti Lelly Sabrina⁴, Maman Sudarisman⁵

^{1,2,4,5}Program Studi Sarjana Terapan Meteorologi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, Indonesia

³Badan Meteorologi Klimatologi Dan Geofisika Cilacap, Indonesia

Email: ¹cahyasugiarto11@gmail.com, ²yosafat.haryanto@stmkg.ac.id, ³adnan.mardika@bmkg.go.id, ⁴purwantilelly.work@gmail.com, ⁵maman.sudarisman@stmkg.ac.id

Abstrak

Curah hujan merupakan unsur meteorologi yang dipengaruhi oleh fenomena atmosfer global dan regional sehingga prediksi curah hujan bulanan yang akurat penting untuk mendukung sektor pertanian, pengelolaan sumber daya air, dan mitigasi bencana hidrometeorologi. Penelitian ini bertujuan membandingkan kinerja model Random Forest dan Long Short-Term Memory (LSTM) dalam memprediksi curah hujan bulanan pada 54 Zona Musim (ZOM) di Jawa Tengah. Data yang digunakan meliputi curah hujan bulanan serta indeks variabilitas iklim Niño 3.4, DMI, WNPPI, dan AUSMI periode 1991–2024. Model dikembangkan menggunakan data pelatihan 1991–2023 dan diuji pada data tahun 2024. Optimasi Random Forest dilakukan menggunakan *TimeSeriesSplit* lima *fold*, sedangkan LSTM menerapkan *look-back window* 12 bulan. Evaluasi model menggunakan koefisien korelasi, RMSE, standar deviasi, bias, dan Metrik *T*. Hasil menunjukkan bahwa model LSTM memiliki performa yang lebih baik dibandingkan Random Forest pada sebagian besar ZOM. LSTM menghasilkan median koefisien korelasi sebesar 0,89 dan median RMSE sebesar 93,98 mm, lebih baik dibandingkan Random Forest dengan median koefisien korelasi 0,78 dan median RMSE 103,30 mm. Namun, Random Forest menunjukkan kemampuan yang sedikit lebih baik dalam merepresentasikan variabilitas curah hujan dan menghasilkan bias yang lebih rendah. Berdasarkan Metrik *T*, LSTM menjadi model terbaik pada 37 dari 54 ZOM (68,5%), sedangkan Random Forest unggul pada 17 ZOM (31,5%). Penelitian ini memberikan evaluasi komprehensif terhadap kedua algoritma pada skala ZOM menggunakan indeks variabilitas iklim sebagai prediktor serta menyediakan referensi dalam pemilihan model prediksi curah hujan untuk mendukung pengembangan sistem prakiraan operasional BMKG.

Kata kunci: Curah Hujan Bulanan, Jawa Tengah, Long Short-Term Memory, Random Forest, Zona Musim.

Comparative Performance of Random Forest and LSTM Models in Monthly Rainfall Forecast for Seasonal Zones in Central Java

Abstract

Rainfall is a meteorological factor influenced by global and regional atmospheric phenomena; therefore, accurate monthly rainfall forecasts are crucial for supporting the agricultural sector, water resource management, and the mitigation of hydrometeorological disasters. This study aims to compare the performance of the Random Forest and Long Short-Term Memory (LSTM) models in predicting monthly rainfall across 54 Seasonal Zones (ZOM) in Central Java. The data used include monthly rainfall and the climate variability indices Niño 3.4, DMI, WNPPI, and AUSMI for the period 1991–2024. The models were developed using training data from 1991–2023 and tested on data from 2024. Random Forest optimization was performed using a five-fold *TimeSeriesSplit*, while the LSTM employed a 12-month *look-back window*. Model evaluation utilized the correlation coefficient, RMSE, standard deviation, bias, and *T*-metric. The results show that the LSTM model outperformed Random Forest in most ZOMs. The LSTM produced a median correlation coefficient of 0.89 and a median RMSE of 93.98 mm, outperforming the Random Forest model, which had a median correlation coefficient of 0.78 and a median RMSE of 103.30 mm. However, Random Forest demonstrated slightly better performance in representing rainfall variability and produced lower bias. Based on the *T*-metric, LSTM was the best model in 37 of 54 ZOMs (68.5%), while Random Forest outperformed in 17 ZOMs (31.5%). This study provides a comprehensive evaluation of both algorithms at the ZOM scale using climate variability indices as

predictors and serves as a reference for selecting rainfall prediction models to support the development of BMKG's operational forecasting system.

Keywords: *Central Java, Long Short-Term Memory, Monthly Rainfall, Random Forest, Seasonal Zones (ZOM).*

1. PENDAHULUAN

Variabilitas curah hujan di Indonesia dipengaruhi oleh interaksi fenomena atmosfer skala global dan regional, seperti El Niño–Southern Oscillation (ENSO), Indian Ocean Dipole (IOD), serta sistem monsun Asia–Australia. Fase El Niño cenderung menurunkan curah hujan dan meningkatkan risiko kekeringan, sedangkan fase La Niña meningkatkan curah hujan di Indonesia [1]. IOD berperan dalam memengaruhi curah hujan di Indonesia bagian barat, dengan fase positif umumnya berkaitan dengan penurunan curah hujan dan fase negatif dengan peningkatan curah hujan [2], [3]. Pada skala regional, monsun Asia meningkatkan curah hujan pada periode Oktober–Maret, sedangkan monsun Australia berasosiasi dengan penurunan curah hujan pada periode April–September [4], [5].

Informasi prediksi curah hujan berperan penting dalam mendukung sektor pertanian, pengelolaan sumber daya air, serta mitigasi bencana hidrometeorologi [6]. Kemampuan prediksi dalam memberikan proyeksi kondisi masa depan menjadikannya sebagai instrumen penting dalam perencanaan dan pengambilan keputusan [7]. Prediksi curah hujan bulanan yang akurat dapat mendukung pengambilan keputusan secara lebih efektif dan menjadi salah satu komponen penting dalam mitigasi kebakaran hutan dan lahan [8], [9]. Jawa Tengah dipilih sebagai wilayah penelitian karena memiliki karakteristik curah hujan yang beragam serta kerentanan yang tinggi terhadap bencana hidrometeorologi sehingga memerlukan informasi prediksi curah hujan yang andal.

Seiring perkembangan teknologi komputasi, pendekatan *machine learning* dan *deep learning* semakin banyak diterapkan dalam prediksi curah hujan [10], [11], [12], [13]. Salah satu metode *machine learning* yang banyak digunakan adalah Random Forest, yaitu algoritma berbasis *ensemble decision tree* yang mampu menangani hubungan *nonlinier*, relatif tahan terhadap *noise* dan *outlier*, serta memiliki risiko *overfitting* yang rendah [14]. Penelitian sebelumnya menunjukkan bahwa Random Forest mampu menghasilkan prediksi meteorologi yang akurat dan sering kali memberikan kinerja yang lebih baik dibandingkan beberapa metode *machine learning* lainnya [15], [16], [17]. Penelitian oleh Meenal et al. (2021) melaporkan bahwa Random Forest memberikan performa terbaik pada prediksi radiasi matahari dengan nilai R^2 sebesar 0,9714 dan MSE sebesar 0,750, lebih baik dibandingkan Support Vector Machine ($R^2 = 0,9385$; $MSE = 0,867$) maupun model regresi berbasis suhu ($R^2 \approx 0,934$; $MSE \approx 1,75$) [15]. Temuan tersebut menunjukkan bahwa Random Forest memiliki kemampuan yang baik dalam memodelkan hubungan nonlinier antarvariabel, meskipun performanya tetap dipengaruhi oleh karakteristik data dan variabel prediktor yang digunakan.

Selain itu, Long Short-Term Memory (LSTM) merupakan salah satu arsitektur *deep learning* yang dirancang untuk mempelajari ketergantungan temporal jangka panjang pada data deret waktu. Karakteristik tersebut menjadikan LSTM banyak digunakan dalam prediksi curah hujan dan berbagai aplikasi hidrometeorologi lainnya. Beberapa penelitian menunjukkan bahwa LSTM mampu menghasilkan prediksi curah hujan maupun unsur meteorologi lainnya dengan akurat dan memiliki performa yang lebih baik dibandingkan arsitektur *deep learning* lain seperti Recurrent Neural Network (RNN) dan Gated Recurrent Unit (GRU) [13], [18], [19]. Sebagai contoh, Alam et al. (2024) membandingkan kinerja RNN, CNN, dan LSTM dalam memprediksi suhu udara pada empat zona iklim yang berbeda. Hasil penelitian menunjukkan bahwa LSTM secara konsisten menghasilkan performa terbaik pada seluruh zona iklim dengan nilai Overall Accuracy (OA) sebesar 92,0% di Dhaka, 94,8% di Moscow, 90,5% di Dubai, dan 85,1% di Brasilia, serta memperoleh nilai Area Under the Curve (AUC) tertinggi sebesar 0,999 [18].

Kajian terhadap penelitian sebelumnya menunjukkan bahwa sebagian besar penelitian prediksi curah hujan berbasis *machine learning* dan *deep learning* masih berfokus pada skala titik stasiun [8], [11], [20]. Kajian prediksi curah hujan bulanan pada skala zona musim (ZOM) di wilayah Jawa Tengah juga masih terbatas. Padahal, pendekatan berbasis ZOM dapat merepresentasikan karakteristik curah hujan regional secara lebih klimatologis dibandingkan pendekatan administratif [21], [22]. Selain itu, perbandingan langsung kinerja Random Forest dan LSTM untuk prediksi curah hujan bulanan pada skala ZOM di Jawa Tengah belum pernah dilakukan secara komprehensif. Akibatnya, belum tersedia informasi yang komprehensif mengenai karakteristik keunggulan masing-masing algoritma pada setiap zona musim.


Berdasarkan kondisi tersebut, penelitian ini memiliki kebaruan pada tiga aspek. Pertama, penelitian dilakukan pada 54 Zona Musim (ZOM) di Jawa Tengah sehingga memberikan evaluasi pada skala klimatologis yang lebih representatif dibandingkan pendekatan berbasis titik stasiun. Kedua, penelitian membandingkan secara komprehensif performa Random Forest dan LSTM menggunakan kombinasi indeks variabilitas iklim

global dan regional, yaitu Niño 3.4, DMI, WNPMI, dan AUSMI sebagai variabel prediktor. Ketiga, evaluasi model dilakukan menggunakan beberapa metrik yang mencakup koefisien korelasi, Root Mean Square Error (RMSE), standar deviasi, bias, dan Metrik T sehingga mampu memberikan penilaian performa model secara lebih menyeluruh.

Berdasarkan kondisi tersebut, penelitian ini bertujuan untuk membandingkan kinerja model Random Forest dan LSTM dalam memprediksi curah hujan bulanan pada zona musim di Jawa Tengah. Evaluasi kinerja dilakukan menggunakan metrik koefisien korelasi, *Root Mean Square Error* (RMSE), standar deviasi, bias, dan Metrik T . Hasil penelitian diharapkan dapat memberikan alternatif pendekatan prediksi curah hujan bulanan yang akurat dan mendukung operasional prakiraan curah hujan BMKG.


2. METODE PENELITIAN

Penelitian ini merupakan penelitian kuantitatif berbasis eksperimental dengan pendekatan deskriptif. Pengolahan data dilakukan menggunakan bahasa pemrograman Python pada platform Google Colaboratory. Tahapan penelitian meliputi *feature engineering*, pembangunan model Random Forest dan LSTM, evaluasi kinerja model, serta penentuan model terbaik menggunakan Metrik T . Alur penelitian ditunjukkan pada Gambar 1 berikut.



Gambar 1. Diagram alir penelitian

2.1. Data



Gambar 2. Peta wilayah penelitian

Data yang digunakan dalam penelitian ini terdiri atas data curah hujan bulanan dan indeks variabilitas iklim periode 1991–2024. Data curah hujan bulanan untuk 54 ZOM monsun di Jawa Tengah (ZOM 214–267) diperoleh dari Sub Bidang Analisis Variabilitas Iklim BMKG. Pembagian wilayah ZOM di Jawa tengah sebagaimana ditunjukkan pada Gambar 2. Data indeks variabilitas iklim meliputi Niño 3.4, Dipole Mode Index (DMI), Western North Pacific Monsoon Index (WNPMI), dan Australian Monsoon Index (AUSMI) yang diperoleh dari APEC Climate Center (APCC). Pemilihan periode yang panjang bertujuan untuk menyediakan jumlah data yang memadai bagi proses *machine learning*, karena ketersediaan data yang besar memungkinkan model mempelajari pola hubungan antarvariabel secara lebih optimal dan meningkatkan stabilitas serta akurasi

model [23]. Selanjutnya, data indeks variabilitas iklim digabungkan dengan data curah hujan berdasarkan kesesuaian waktu sehingga diperoleh satu *dataset* terintegrasi untuk setiap ZOM.

2.2. Feature Engineering

Feature engineering dilakukan untuk meningkatkan kualitas representasi data yang digunakan selama proses pelatihan model, sehingga algoritma *machine learning* maupun *deep learning* dapat menangkap pola dan hubungan *nonlinier* dalam data yang mungkin tidak teridentifikasi pada data mentah [24]. Tahapan *feature engineering* yang diterapkan meliputi tiga proses. Proses pertama adalah *cyclical temporal encoding*, yaitu transformasi variabel bulan ke dalam komponen sinus dan cosinus untuk merepresentasikan pola siklikal waktu secara lebih realistis [25]. Metode ini diterapkan khusus pada data untuk model LSTM, karena model berbasis pohon keputusan seperti Random Forest cenderung kesulitan memanfaatkan representasi siklikal akibat mekanisme splitting yang bekerja pada satu fitur dalam satu waktu [26]. Proses kedua adalah *min-max scaling*, yaitu normalisasi seluruh variabel numerik ke dalam rentang 0 hingga 1 untuk menghindari bias antarfitur selama pelatihan [27]. Proses ketiga adalah penambahan fitur lag curah hujan, yaitu informasi curah hujan pada periode sebelumnya yang dipilih berdasarkan tiga nilai autokorelasi tertinggi pada masing-masing ZOM, dengan tujuan membantu model menangkap ketergantungan temporal dan pola musiman curah hujan [28]. *Dataset* yang sudah melalui tahap ini kemudian dibagi menjadi data pelatihan selama 33 tahun (1991–2023) dan data pengujian selama 1 tahun (2024).

2.3. Modeling Random Forest

Random Forest Regressor digunakan sebagai model *machine learning* dalam penelitian ini. Pelatihan dilakukan secara terpisah pada setiap ZOM dengan dataset dan konfigurasi hyperparameter yang disesuaikan. Konfigurasi dan ruang pencarian *hyperparameter* ditampilkan pada Tabel 1. *Hyperparameter* terbaik hasil proses *tuning* kemudian digunakan untuk melatih ulang model menggunakan seluruh data pelatihan. Selanjutnya, dilakukan prediksi curah hujan bulanan tahun 2024 secara iteratif dengan memanfaatkan hasil prediksi periode sebelumnya sebagai fitur lag pada periode berikutnya.

Tabel 1. Konfigurasi model Random Forest dan *hyperparameter tuning*

Konfigurasi Model	
Algoritma	Random Forest Regressor
Variabel target	Curah hujan bulanan
Variabel input	Niño 3.4, DMI, WNPMI, AUSMI, lag curah hujan
Normalisasi data	MinMaxScaler
Random seed	42
Parallel processing	n_jobs = -1
Hyperparameter Tuning	
Algoritma tuning	RandomizedSearchCV
Jumlah iterasi pencarian (n_iter)	50
Strategi validasi	TimeSeriesSplit (n_splits = 5)
Metrik optimasi	neg_mean_squared_error
n_estimators	100, 200, 300, 500
max_depth	5, 10, 15, None
min_samples_split	2, 4, 6, 8
min_samples_leaf	1, 3, 5, 7
max_features	sqrt, log2
criterion	squared_error, absolute_error
Refit model terbaik	Ya
Random seed tuning	42

2.4. Modeling LSTM

LSTM digunakan sebagai model *deep learning* dalam penelitian ini. Pelatihan dilakukan secara terpisah pada setiap ZOM dengan dataset dan konfigurasi hyperparameter yang disesuaikan. Konfigurasi model dan ruang pencarian *hyperparameter* ditampilkan pada Tabel 2. *Hyperparameter* terbaik hasil proses *tuning* kemudian digunakan untuk melatih ulang model menggunakan seluruh data pelatihan dengan maksimum 500 epoch. Model hasil pelatihan selanjutnya digunakan untuk memprediksi curah hujan bulanan pada periode pengujian tahun 2024.

Tabel 2. Konfigurasi model LSTM dan *hyperparameter tuning*

Konfigurasi Model	
Algoritma	Long Short-Term Memory (LSTM)
Variabel target	Curah hujan bulanan
Variabel input	Niño 3.4, DMI, WNPMI, AUSMI, month_sin, month_cos
Normalisasi data	MinMaxScaler
Look-back window	12 bulan
Lead time prediksi	12 bulan
Jumlah lapisan LSTM	2 layer
Fungsi aktivasi	tanh
Batch Normalization	Ya
Dropout	Ya
Random seed	42
Hyperparameter Tuning	
Algoritma tuning	Keras Tuner Random Search
Objective function	val_loss
Jumlah trial (max_trials)	10
Validation split	20%
Shuffle data	FALSE
Epoch tuning	Maksimum 100
Batch size	32
Optimizer	Adam
Loss function	Mean Squared Error (MSE)
units1	32, 64, 96, 128
units2	32, 64, 96, 128
dropout layer 1	0,1; 0,2; 0,3; 0,4; 0,5
dropout layer 2	0,1; 0,2; 0,3; 0,4; 0,5
learning rate	0,01; 0,001; 0,0001
Early Stopping	patience = 20
ReduceLROnPlateau	factor = 0,5; patience = 10
Refit model terbaik	Ya
Epoch refit	Maksimum 500

2.5. Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan dengan membandingkan hasil prediksi terhadap data observasi menggunakan empat metrik, yaitu koefisien korelasi Pearson, *Root Mean Square Error* (RMSE), standar deviasi, dan bias. Koefisien korelasi digunakan untuk mengukur keeratan hubungan linear antara hasil prediksi dan observasi, dengan nilai berkisar antara -1 hingga 1 [29]. RMSE digunakan untuk mengukur besarnya rata-rata kesalahan prediksi, dengan nilai yang semakin kecil menunjukkan kinerja model yang semakin baik [30]. Standar deviasi digunakan untuk membandingkan tingkat variabilitas hasil prediksi terhadap variabilitas data observasi [31], sedangkan bias digunakan untuk mengidentifikasi kecenderungan model dalam melakukan *overestimate* atau *underestimate* terhadap curah hujan observasi [32].

Penentuan model dengan kinerja terbaik pada masing-masing ZOM dilakukan menggunakan Metrik T , yang menggabungkan informasi koefisien korelasi, *Mean Square Error* (MSE), standar deviasi, dan bias ke dalam satu nilai tunggal, sebagaimana dirumuskan pada persamaan berikut [33].


$$T = \left[\frac{1+r}{2} \right] \times \left[1 - \frac{MSE}{Bias^2 + SD_{model}^2 + SD_{obs}^2} \right] \quad (1)$$

dengan r adalah koefisien korelasi, MSE adalah *Mean Square Error* (kuadrat dari RMSE), SD_{model} adalah standar deviasi hasil prediksi, dan SD_{obs} adalah standar deviasi data observasi. Semakin tinggi nilai Metrik T mendekati 1 , semakin baik kesesuaian model terhadap pola dan magnitudo curah hujan observasi secara simultan. Model dengan nilai Metrik T tertinggi pada masing-masing ZOM ditetapkan sebagai model terbaik untuk wilayah tersebut.

3. HASIL DAN PEMBAHASAN


3.1. Evaluasi Metrik Koefisien Korelasi

Evaluasi koefisien korelasi digunakan untuk mengukur kemampuan model dalam merepresentasikan pola variasi curah hujan bulanan hasil observasi. Model Random Forest menghasilkan koefisien korelasi positif pada seluruh ZOM dengan rentang nilai yang relatif bervariasi. Sementara itu, model LSTM menunjukkan nilai korelasi yang secara umum lebih tinggi dibandingkan Random Forest, meskipun terdapat ZOM dengan korelasi negatif sebagaimana ditunjukkan pada Gambar 3. Sebanyak 38 dari 54 ZOM pada model LSTM memiliki koefisien korelasi di atas 0,75, sedangkan pada Random Forest hanya 14 ZOM yang mencapai nilai tersebut. Hasil ini menunjukkan bahwa LSTM lebih mampu merepresentasikan pola variasi curah hujan bulanan pada sebagian besar ZOM di Jawa Tengah.



Gambar 3. Distribusi spasial koefisien korelasi di seluruh ZOM Jawa Tengah pada (a) Random Forest dan (b) LSTM

Berdasarkan boxplot koefisien korelasi pada Gambar 4, median koefisien korelasi model LSTM sebesar 0,89, lebih tinggi dibandingkan Random Forest yang sebesar 0,78. Selain itu, distribusi nilai korelasi LSTM cenderung berada pada rentang yang lebih tinggi dan memiliki jumlah *outlier* bawah yang lebih sedikit, yaitu tiga ZOM dibandingkan tujuh ZOM pada Random Forest. Hasil ini menunjukkan bahwa model LSTM lebih mampu menangkap pola temporal curah hujan bulanan secara konsisten pada sebagian besar wilayah Jawa Tengah dibandingkan model Random Forest.




Gambar 4. Boxplot koefisien korelasi model Random Forest dan LSTM

3.2 Evaluasi Metrik RMSE


Sebagian besar ZOM pada model Random Forest memiliki nilai RMSE pada rentang 75–150 mm. Sementara itu, model LSTM menunjukkan distribusi RMSE yang lebih bervariasi, termasuk ZOM 232 dengan nilai RMSE yang jauh lebih tinggi dibandingkan wilayah lainnya. Secara keseluruhan, LSTM menghasilkan nilai

RMSE yang lebih rendah pada 31 dari 54 ZOM, sedangkan Random Forest lebih unggul pada 23 ZOM. Hasil ini menunjukkan bahwa LSTM cenderung menghasilkan kesalahan prediksi yang lebih kecil pada sebagian besar wilayah Jawa Tengah. Perbandingan distribusi spasial nilai RMSE ditampilkan pada Gambar 5 berikut.



Gambar 5. Perbandingan distribusi spasial RMSE (a) Random Forest dan (b) LSTM


Gambar 6 menunjukkan bahwa median RMSE model LSTM sebesar 93,98 mm, lebih rendah dibandingkan Random Forest yang sebesar 103,30 mm. Temuan ini menunjukkan bahwa secara umum kesalahan prediksi LSTM lebih kecil pada sebagian besar ZOM. Namun, Random Forest memiliki distribusi RMSE yang lebih homogen tanpa adanya nilai *outlier*, sedangkan LSTM memiliki satu *outlier* pada ZOM 232 yang mengindikasikan adanya wilayah dengan performa yang jauh lebih rendah dibandingkan ZOM lainnya. Dengan demikian, LSTM cenderung lebih akurat secara umum, sedangkan Random Forest menunjukkan kestabilan performa yang lebih baik antarwilayah.



Gambar 6. Boxplot RMSE model Random Forest dan LSTM


3.3. Evaluasi Metrik Standar Deviasi

Standar deviasi digunakan untuk mengevaluasi kemampuan model dalam merepresentasikan tingkat variabilitas curah hujan bulanan. Berdasarkan Gambar 7 dan 8, standar deviasi observasi berkisar pada rentang 75–225 mm, sedangkan Random Forest dan LSTM masing-masing memiliki rentang 25–175 mm dan 0–175 mm. Nilai standar deviasi yang lebih rendah pada kedua model menunjukkan bahwa hasil prediksi cenderung lebih halus (*smoother*) dibandingkan data observasi sehingga variasi curah hujan yang ekstrem belum sepenuhnya dapat direpresentasikan. Berdasarkan kedekatan nilai standar deviasi terhadap observasi, Random Forest memberikan hasil yang lebih baik pada 30 dari 54 ZOM, sedangkan LSTM lebih baik pada 24 ZOM.




Gambar 7. Perbandingan distribusi spasial standar deviasi (a) Random Forest, (b) LSTM, dan (c) Observasi

Median standar deviasi observasi mencapai 149,97 mm, jauh lebih tinggi dibandingkan median Random Forest dan LSTM yang masing-masing sebesar 83,40 mm dan 82,53 mm. Hasil ini mengonfirmasi bahwa kedua model cenderung mengestimasi variabilitas curah hujan lebih rendah dibandingkan kondisi aktual. Meskipun demikian, Random Forest menunjukkan representasi variabilitas yang sedikit lebih baik dibandingkan LSTM karena memiliki median standar deviasi yang lebih mendekati observasi.




Gambar 8. Boxplot Standar Deviasi Model dan Observasi

3.4. Evaluasi Metrik Bias



Gambar 9. Perbandingan distribusi spasial Bias (a) Random Forest dan (b) LSTM

Distribusi bias pada Random Forest cenderung lebih homogen dengan dominasi bias negatif pada sebagian besar ZOM, yang menunjukkan kecenderungan model untuk melakukan *underestimate* terhadap curah hujan observasi. Sebaliknya, LSTM menunjukkan distribusi bias yang lebih bervariasi dengan beberapa ZOM memiliki bias positif yang tinggi, terutama pada ZOM 227, 232, dan 239 sebagaimana terlihat pada Gambar 9. Hasil ini menunjukkan bahwa Random Forest menghasilkan penyimpangan yang lebih konsisten antarwilayah, sedangkan LSTM cenderung menghasilkan *overestimate* pada sebagian besar ZOM.




Gambar 10. Boxplot Bias model Random Forest dan LSTM

Berdasarkan Gambar 10, median bias Random Forest sebesar 13,70 mm, lebih rendah dibandingkan median bias LSTM yang mencapai 43,58 mm. Selain itu, distribusi bias Random Forest lebih sempit dan tidak menunjukkan adanya outlier, yang mengindikasikan tingkat kesalahan sistematis yang relatif konsisten pada seluruh ZOM. Sebaliknya, LSTM memiliki distribusi bias yang lebih lebar, menunjukkan bahwa besarnya penyimpangan terhadap observasi bervariasi antarwilayah. Temuan ini mengindikasikan bahwa Random Forest lebih mampu mempertahankan kestabilan bias dibandingkan LSTM.


3.5. Evaluasi Model Terbaik (Metrik T)

Metrik T digunakan untuk mengevaluasi performa model secara komprehensif dengan menggabungkan informasi dari koefisien korelasi, MSE, standar deviasi, dan bias ke dalam satu indeks evaluasi tunggal. Metrik ini mampu menilai kesesuaian pola dan magnitudo hasil prediksi terhadap data observasi secara simultan, sehingga dapat digunakan untuk menentukan model terbaik pada masing-masing zona musim (ZOM). Semakin tinggi nilai Metrik T dan semakin mendekati 1, semakin baik kemampuan model dalam merepresentasikan karakteristik curah hujan bulanan.




Gambar 11. Perbandingan distribusi spasial metrik T di seluruh ZOM Jawa Tengah (a) Random Forest dan (b) LSTM

Berdasarkan Gambar 11, model Random Forest menghasilkan nilai Metrik T pada rentang 0,1–0,9, dengan nilai tertinggi pada ZOM 226 dan ZOM 237 (0,8–0,9) serta nilai terendah pada ZOM 229 dan ZOM 230 (0,0–0,1), yang mengindikasikan bahwa model ini masih mengalami kesulitan dalam merepresentasikan pola dan besarnya variasi curah hujan secara bersamaan pada beberapa wilayah. Sementara itu, model LSTM menghasilkan nilai Metrik T pada rentang 0,0–0,9, dengan nilai tertinggi pada ZOM 215, ZOM 223, dan ZOM 248 (0,8–0,9), sedangkan nilai terendah ditemukan pada ZOM 230 dan ZOM 232 (0,0–0,1). Secara spasial, wilayah dengan nilai Metrik T tinggi pada LSTM lebih banyak dibandingkan Random Forest, terutama di bagian timur, utara, dan barat Jawa Tengah. Berdasarkan perbandingan antarmodel, LSTM memberikan performa terbaik pada 37 ZOM (68,5%) dan Random Forest pada 17 ZOM (31,5%). Hal ini menunjukkan bahwa LSTM lebih mampu menghasilkan prediksi yang sesuai secara pola temporal sekaligus merepresentasikan variabilitas dan besaran curah hujan, meskipun beberapa wilayah seperti ZOM 226, 237, 257, dan 262 masih lebih baik dimodelkan menggunakan Random Forest.



Gambar 12. Boxplot metrik T model Random Forest dan LSTM

Berdasarkan distribusi statistik nilai Metrik T kedua model pada Gambar 12. Model Random Forest memiliki nilai minimum 0,05, median 0,62, dan nilai maksimum 0,83. Model LSTM memiliki nilai minimum 0,18, median 0,68 dan nilai maksimum 0,85. Nilai median yang lebih tinggi pada LSTM mengonfirmasi bahwa secara umum model ini memiliki performa yang lebih baik pada sebagian besar ZOM. Nilai minimum LSTM yang lebih tinggi dibandingkan Random Forest juga mengindikasikan bahwa performa terburuk LSTM masih relatif lebih baik. Dari sisi pencilan, Random Forest memiliki satu *outlier* bawah, sedangkan LSTM memiliki dua *outlier* bawah, yang menunjukkan adanya beberapa ZOM dengan karakteristik curah hujan yang lebih kompleks sehingga sulit direpresentasikan oleh model.



Gambar 13. Peta Distribusi Model Terbaik Berdasarkan Metrik T di Seluruh ZOM Jawa Tengah

Berdasarkan Gambar 13, model LSTM mendominasi sebagian besar wilayah ZOM di Jawa Tengah sebagaimana ditunjukkan dengan warna biru, sedangkan wilayah yang lebih sesuai dimodelkan oleh Random Forest ditunjukkan dengan warna merah. Dominasi LSTM terlihat terutama pada wilayah bagian timur, selatan, dan sebagian wilayah tengah Jawa Tengah, sedangkan Random Forest menunjukkan performa lebih baik pada beberapa wilayah seperti ZOM 226, 237, dan 262. Secara keseluruhan, hasil evaluasi menggunakan Metrik T menunjukkan bahwa model LSTM lebih mampu menghasilkan keseimbangan antara akurasi prediksi, representasi variabilitas, dan kestabilan kesalahan dibandingkan Random Forest pada sebagian besar ZOM di Jawa Tengah.

4. KESIMPULAN

Hasil evaluasi menunjukkan bahwa model LSTM secara umum memiliki kemampuan yang lebih baik dalam memprediksi curah hujan bulanan dibandingkan Random Forest, sebagaimana ditunjukkan oleh nilai koefisien korelasi yang lebih tinggi, median RMSE yang lebih rendah, serta nilai Metrik T yang lebih besar pada sebagian besar ZOM. Kemampuan LSTM dalam mempelajari ketergantungan temporal pada data deret waktu memberikan keuntungan dalam prediksi curah hujan bulanan di sebagian besar wilayah Jawa Tengah, dengan model ini menjadi pilihan terbaik pada 37 dari 54 ZOM (68,5%) berdasarkan evaluasi Metrik T . Meskipun demikian, Random Forest menunjukkan performa yang lebih stabil dengan distribusi RMSE dan bias yang lebih homogen serta kemampuan yang sedikit lebih baik dalam merepresentasikan variabilitas curah hujan, sehingga tetap menjadi pilihan yang lebih unggul pada 17 ZOM (31,5%) yang memiliki karakteristik tertentu seperti ZOM 226, 237, 257, dan 262.

Penelitian ini menghasilkan evaluasi komprehensif terhadap performa model Random Forest dan LSTM dalam prediksi curah hujan bulanan pada 54 Zona Musim (ZOM) di Jawa Tengah menggunakan kombinasi indeks variabilitas iklim global dan regional sebagai variabel masukan. Hasil penelitian menunjukkan bahwa tidak terdapat satu model yang secara konsisten memberikan performa terbaik pada seluruh wilayah, sehingga pemilihan model prediksi perlu mempertimbangkan karakteristik masing-masing ZOM. Temuan ini memperkaya kajian prediksi curah hujan berbasis *machine learning* pada skala zona musim serta memberikan gambaran mengenai keunggulan masing-masing model.

Berdasarkan temuan tersebut, model LSTM direkomendasikan sebagai pendekatan utama untuk prediksi curah hujan bulanan pada sebagian besar wilayah ZOM di Jawa Tengah, sedangkan Random Forest tetap layak dipertimbangkan pada wilayah yang menunjukkan performa lebih baik. Selain memberikan referensi dalam pemilihan model prediksi curah hujan, hasil penelitian ini juga dapat mendukung pengembangan sistem prediksi curah hujan BMKG melalui implementasi model terbaik pada masing-masing ZOM. Penelitian selanjutnya disarankan untuk mengeksplorasi algoritma *machine learning* lainnya, memperluas ruang pencarian hyperparameter, serta mengintegrasikan variabel meteorologi tambahan agar akurasi dan kemampuan generalisasi model dapat terus ditingkatkan.

DAFTAR PUSTAKA

- [1] U. Hidayat, S. Prasetyo, Y. Donni Haryanto, and N. Florida Riama, "Pengaruh ENSO Terhadap Curah Hujan dan Kelembapan Relatif serta Suhu Permukaan Laut di Sulawesi," *BGB*, vol. 2, no. 2, pp. 88–96, Mar. 2022, doi: 10.31172/bgb.v2i2.56.

-
- [2] N. D. Rahayu, B. Sasmito, and N. Bashit, "ANALISIS PENGARUH FENOMENA INDIAN OCEAN DIPOLE (IOD) TERHADAP CURAH HUJAN DI PULAU JAWA," 2018.
- [3] A. F. I. Susilo, G. Harsono, and A. Wirasatya, "Pengaruh IOD (Indian Ocean Dipole) Terhadap Variabilitas Distribusi Suhu Permukaan Laut dan Klorofil-A Pada Tahun 2019 di Perairan Meulaboh, Kepulauan Sinabang, Provinsi Aceh," *Jurnal Hidrografi Indonesia*, vol. 4, no. 2, pp. 57–72, Jan. 2024, doi: 10.62703/jhi.v4i2.32.
- [4] F. S. Pandia, B. Sasmito, and A. Sukmono, "ANALISIS PENGARUH ANGIN MONSUN TERHADAP PERUBAHAN CURAH HUJAN DENGAN PENGINDERAAN JAUH (STUDI KASUS: PROVINSI JAWA TENGAH)," *Jurnal Geodesi Undip; Vol 8, No 1 (2019)DO - 10.14710/jgundip.2019.22581*, Jan. 2019, [Online]. Available: <https://ejournal3.undip.ac.id/index.php/geodesi/article/view/22581>
- [5] BMKG, *Peta Rata-rata Curah Hujan dan Hari Hujan Periode 1991 – 2020 Indonesia*. Jakarta: Pusat Informasi Perubahan Iklim BMKG, 2021.
- [6] BMKG, "Buletin Informasi Iklim Edisi April 2025," Badan Meteorologi Klimatologi Dan Geofisika, Semarang, Indonesia, 113, Apr. 2025. [Online]. Available: <https://iklimjateng.info/>
- [7] M. S. Putri, S. Junaidi, and A. Mardiyah, "Pemodelan dan Prediksi Tingkat Kemiskinan Provinsi Sumatera Barat Menggunakan Support Vector Machine," vol. 7, no. 1, 2026, doi: 10.37859/coscitech.v7i1.11207.
- [8] I. Mahmuda and A. W. Ciptaningtyas, "PREDIKSI CURAH HUJAN BULANAN MENGGUNAKAN METODE NAÏVE BAYES DI KOTA MALANG," vol. 13, 2024.
- [9] D. Sangaji and T. Sutabri, "Analisis XGBoost dan Random Forest untuk Prediksi Curah Hujan dalam Mendukung Mitigasi Karhutla," *Jurnal Pustaka AI*, vol. 5, no. 1, pp. 13–18, Apr. 2025, doi: 10.55382/jurnalpustakaai.v5i1.905.
- [10] G. Z. Muflih, S. Sunardi, and A. Yudhana, "Jaringan Saraf Tiruan Backpropagation untuk Prediksi Curah Hujan di Wilayah Kabupaten Wonosobo," *MUST*, vol. 4, no. 1, p. 45, Jul. 2019, doi: 10.30651/must.v4i1.2670.
- [11] S. Dong, "Precipitation Prediction Using Long Short-Term Memory Networks: Improving Seasonal Rainfall Forecast Accuracy for Flood and Drought Prevention," in *2024 International Conference on Advances in Electrical Engineering and Computer Applications (AEECA)*, Dalian, China: IEEE, Aug. 2024, pp. 345–349. doi: 10.1109/AEECA62331.2024.00067.
- [12] R. Rubangi, A. Hermawan, and D. Avianto, "Prediksi Curah Hujan Wilayah Provinsi Yogyakarta dengan Algoritma Neural Network," *JASIEK*, vol. 3, no. 1, pp. 47–54, Jun. 2021, doi: 10.26905/jasiek.v3i1.6204.
- [13] M. Unik, M. E. Aldo Fahrurrozi, H. Harmaini, and C. Kusuma, "MODEL PREDIKSI CURAH HUJAN MENGGUNAKAN ALGORTIMA MACHINE LEARNING YANG DITINGKATKAN," *CoSciTech*, vol. 5, no. 2, pp. 439–448, Aug. 2024, doi: 10.37859/coscitech.v5i2.7629.
- [14] H. Andrianof, Aggy Pramana Gusman, and Okta Andrica Putra, "Implementasi Algoritma Random Forest untuk Prediksi Kelulusan Mahasiswa Berdasarkan Data Akademik: Studi Kasus di Perguruan Tinggi Indonesia," *Ju. Sa. In. Te.*, vol. 4, no. 1, pp. 24–28, Feb. 2025, doi: 10.62357/jsit.v4i2.464.
- [15] R. Meenal, P. A. Michael, D. Pamela, and E. Rajasekaran, "Weather prediction using random forest machine learning model," *IJECS*, vol. 22, no. 2, p. 1208, May 2021, doi: 10.11591/ijeecs.v22.i2.pp1208-1215.
- [16] F. Z. Che Rose, N. A. K. Rosili, and M. F. Marsani, "Comparison of machine learning model performance for predicting the climate variables in Johor Bahru, Malaysia," *Sci Rep*, vol. 15, no. 1, p. 23465, Jul. 2025, doi: 10.1038/s41598-025-08033-y.
- [17] M. Montenegro, R. Céleri, J. Orellana-Alvear, P. Muñoz, and M. Córdova, "Precipitation forecasting using random forest over an ecuadorian andes basin," *Meteorol Atmos Phys*, vol. 137, no. 1, p. 5, Jan. 2025, doi: 10.1007/s00703-024-01053-9.
- [18] F. Alam, M. Islam, A. Deb, and S. S. Hossain, "Comparison of deep learning models for weather forecasting in different climatic zones," *J. Comput. Sci. Eng.*, vol. 5, no. 1, pp. 12–19, Apr. 2024, doi: 10.36596/jcse.v5i1.729.
- [19] D. Supriatna, S. Anggai, and T. Tukiyat, "Analisis Prediksi Curah Hujan di Kota Tangerang Menggunakan Metode LSTM dan GRU," *Jurnal Pustaka AI*, vol. 5, no. 2, pp. 119–131, Aug. 2025, doi: 10.55382/jurnalpustakaai.v5i2.1068.

-
- [20] D. Desmonda, T. Tursina, and M. A. Irwansyah, "Prediksi Besaran Curah Hujan Menggunakan Metode Fuzzy Time Series," *justin*, vol. 6, no. 4, p. 141, Oct. 2018, doi: 10.26418/justin.v6i4.27036.
 - [21] Y. S. Swarinoto and E. E. S. Makmur, "SIMULASI PREDIKSI PROBABILITAS AWAL MUSIM HUJAN DAN PANJANG MUSIM HUJAN DI ZOM 126 DENPASAR," *JMG*, vol. 11, no. 1, Jun. 2010, doi: 10.31172/jmg.v11i1.56.
 - [22] W. G. Kurnia, "PREDIKSI CURAH HUJAN BULANAN MENGGUNAKAN MULTI PREDIKTOR DI ZOM 313 SULAWESI TENGGARA," *Buletin Meteorologi, Klimatologi, Kualitas Udara, Geofisika, dan Lingkungan*, vol. 13, no. 01, pp. 1–5, Aug. 2022, doi: 10.46824/megasains.v13i01.44.
 - [23] A. Althnian *et al.*, "Impact of Dataset Size on Classification Performance: An Empirical Evaluation in the Medical Domain," *Applied Sciences*, vol. 11, no. 2, p. 796, Jan. 2021, doi: 10.3390/app11020796.
 - [24] L. Santoso and Priyadi, "Comparative Study of Feature Engineering Techniques for Predictive Data Analytics," *JTIE*, vol. 3, no. 2, pp. 417–435, Aug. 2024, doi: 10.51903/jtie.v3i2.225.
 - [25] A. Bansal, K. Balaji, and Z. Lalani, "Temporal Encoding Strategies for Energy Time Series Prediction," 2025, *arXiv*. doi: 10.48550/ARXIV.2503.15456.
 - [26] E. Lewinson, "Three Approaches to Encoding Time Information as Features for ML Models," NVIDIA Technical Blog. Accessed: Jan. 23, 2026. [Online]. Available: <https://developer.nvidia.com/blog/three-approaches-to-encoding-time-information-as-features-for-ml-models/>
 - [27] A. Pranolo *et al.*, "Enhanced Multivariate Time Series Analysis Using LSTM: A Comparative Study of Min-Max and Z-Score Normalization Techniques," *Ilk. J. Ilm.*, vol. 16, no. 2, pp. 210–220, Aug. 2024, doi: 10.33096/ilkom.v16i2.2333.210-220.
 - [28] W. M. Ridwan, M. Sapitang, A. Aziz, K. F. Kushiar, A. N. Ahmed, and A. El-Shafie, "Rainfall forecasting model using machine learning methods: Case study Terengganu, Malaysia," *Ain Shams Engineering Journal*, vol. 12, no. 2, pp. 1651–1663, Jun. 2021, doi: 10.1016/j.asej.2020.09.011.
 - [29] A. Temizel, T. Halici, B. Logoglu, T. T. Temizel, F. Omruuzun, and E. Karaman, "Experiences on Image and Video Processing with CUDA and OpenCL," in *GPU Computing Gems Emerald Edition*, Elsevier, 2011, pp. 547–567. doi: 10.1016/B978-0-12-384988-5.00034-6.
 - [30] T. Chai and R. R. Draxler, "Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature," *Geosci. Model Dev.*, vol. 7, no. 3, pp. 1247–1250, Jun. 2014, doi: 10.5194/gmd-7-1247-2014.
 - [31] D. G. Altman and J. M. Bland, "Standard deviations and standard errors," *BMJ*, vol. 331, no. 7521, p. 903, Oct. 2005, doi: 10.1136/bmj.331.7521.903.
 - [32] B. A. Walther and J. L. Moore, "The concepts of bias, precision and accuracy, and their use in testing the performance of species richness estimators, with a literature review of estimator performance," *Ecography*, vol. 28, no. 6, pp. 815–829, Dec. 2005, doi: 10.1111/j.2005.0906-7590.04112.x.
 - [33] B. Tian *et al.*, "Development of a Model Performance Metric and Its Application to Assess Summer Precipitation over the U.S. Great Plains in Downscaled Climate Simulations," *Journal of Hydrometeorology*, vol. 18, no. 10, pp. 2781–2799, Oct. 2017, doi: 10.1175/JHM-D-17-0045.1.