

EVALUASI MODEL LONG SHORT-TERM MEMORY (LSTM) UNTUK PREDIKSI CURAH HUJAN DI ZONA MUSIM (ZOM) PROVINSI JAWA TENGAH

¹⁾Catur Handika Kurniawan Winardi, ²⁾Fendy Arifianto, ³⁾Yahya Darmawan, ⁴⁾Ervan Ferdiansyah

¹⁾Program Studi Sarjana Terapan Klimatologi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, email: caturhandika28@gmail.com

²⁾Program Studi Sarjana Terapan Klimatologi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, email: fendy.arifianto@bmkg.go.id

³⁾Program Studi Sarjana Terapan Klimatologi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, email: yahya.darmawan@bmkg.go.id

⁴⁾Program Studi Sarjana Terapan Klimatologi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, email: ervan.kli29@gmail.com

Abstrak

Provinsi Jawa Tengah merupakan salah satu sentra produksi pertanian nasional yang juga rentan terhadap bencana hidrometeorologi, sehingga informasi prakiraan curah hujan dasarian yang akurat diperlukan untuk mendukung sektor tersebut. Penelitian ini bertujuan mengevaluasi kinerja model *Long Short-Term Memory* (LSTM) dalam memprediksi curah hujan dasarian pada 54 Zona Musim (ZOM) di Jawa Tengah. Data yang digunakan berupa curah hujan hasil *blending* serta angin zonal (U850), angin meridional (V850), dan kelembapan relatif (RH850) lapisan 850 hPa dari ERA5. Data dibagi menjadi *training* tahun 1991–2015, *validation* tahun 2016–2020, dan *testing* tahun 2021–2024. Seleksi prediktor menggunakan *Light Gradient Boosting Machine* (LightGBM) dan *SHapley Additive exPlanations* (SHAP), yang menunjukkan RH850 dan U850 sebagai prediktor dengan kontribusi terbesar. Hasil penelitian menunjukkan model LSTM mampu merepresentasikan pola temporal dan tren musiman curah hujan dengan baik, dengan korelasi berkisar antara 0,53 hingga 0,81, RMSE antara 27,70 hingga 76,47 mm, MAE antara 19,41 hingga 55,63 mm, dan bias antara –17,27 hingga 13,47 mm. Namun, performa model masih bervariasi pada setiap ZOM dan kurang optimal dalam mengestimasi puncak curah hujan ekstrem.

Kata Kunci: LSTM, Curah hujan, Prediksi

Abstract

Central Java Province is one of Indonesia's major agricultural production centers and is also highly vulnerable to hydrometeorological disasters, therefore, accurate decade (10-day) rainfall forecast information is essential to support that sector. This study aims to evaluate the performance of the *Long Short-Term Memory* (LSTM) model in predicting decade rainfall across 54 Seasonal Zones (ZOM) in Central Java. The datasets used consisted of blended rainfall data and atmospheric predictors, including zonal wind (U850), meridional wind (V850), and relative humidity (RH850) at the 850 hPa level from ERA5. The data were divided into a training dataset for 1991–2015, a validation dataset for 2016–2020, and a testing dataset for 2021–2024. Predictor selection was performed using *Light Gradient Boosting Machine* (LightGBM) and *SHapley Additive exPlanations* (SHAP), which identified RH850 and U850 as the most influential predictors. The results show that the LSTM model was able to effectively capture the temporal patterns and seasonal trends of rainfall, with correlation ranging from 0.53 to 0.81, RMSE ranging from 27.70 to 76.47 mm, MAE ranging from 19.41 to 55.63 mm, and bias ranging from –17.27 to 13.47 mm. However, model performance varied across ZOM and remained less accurate in estimating extreme rainfall peaks.

Keywords: LSTM, Rainfall, Prediction

I. PENDAHULUAN

Curah hujan merupakan salah satu unsur iklim yang menjadi faktor penting dalam berbagai aspek kehidupan seperti pengelolaan sumber daya air, sektor pertanian, dan mitigasi bencana (Kurniyaningrum *et al.*, 2025). Dalam budidaya tanaman, kondisi curah hujan mempengaruhi ketersediaan air tanah, penetapan jadwal tanam, hingga produktivitas panen (Wihardjaka *et al.*, 2020). Namun, sebagai wilayah tropis, curah hujan di Indonesia memiliki variabilitas spasial dan temporal yang tinggi, sehingga intensitas maupun waktu kejadiannya cenderung fluktuatif dan sulit diprediksi (Mamenun *et al.*, 2014). Curah hujan yang tidak menentu dan ekstrem tersebut sering memicu bencana hidrometeorologi seperti banjir dan kekeringan yang berdampak langsung pada penurunan produktivitas pertanian serta kondisi sosial-ekonomi masyarakat (Aeni & Muhammad, 2024; Yanfatriani *et al.*, 2024).

Provinsi Jawa Tengah memegang peran sentral dalam ketahanan pangan nasional, sekaligus wilayah dengan tingkat kerentanan iklim yang tinggi. Jawa Tengah menempati posisi kedua dalam produksi padi nasional dengan luas panen melebihi 1,55 juta hektare dan total produksi mencapai 8,89 juta ton (BPS, 2025). Di sisi lain, lebih dari 90% kejadian bencana di Indonesia didominasi oleh fenomena hidrometeorologi (BNPB, 2025). Jawa Tengah mencatatkan lebih dari 200 peristiwa bencana sepanjang tahun 2024 dengan dominasi kejadian banjir yang umum terjadi di kawasan pesisir utara dan tanah longsor pada wilayah bagian tengah. Kejadian bencana di wilayah ini disebabkan oleh variabilitas curah hujan yang berkaitan dengan dinamika iklim global dan regional, serta interaksinya dengan mekanisme atmosfer lokal dan kondisi topografi yang beragam (Hadibasyir *et al.*, 2015; Satyawardhana & Yulihastin, 2016). Penyediaan informasi prakiraan curah hujan yang lebih akurat terutama dalam skala dasarian menjadi kebutuhan penting untuk mendukung mitigasi bencana serta menjaga ketahanan pangan dan stabilitas ekonomi regional.

Untuk menghasilkan prediksi curah hujan yang akurat dan konsisten di wilayah tropis sampai saat ini masih menjadi tantangan karena kondisi atmosfernya sangat dinamis (Ejike & Ndzi, 2025). Selama ini, penggunaan metode statistik konvensional sering kali kurang mampu menangkap hubungan *non-linear* serta belum terlalu baik dalam menangkap pola curah hujan yang fluktuatif (Mhatre & Cooley, 2024). Sebagai alternatif, pemanfaatan *machine learning* kini berkembang pesat dalam bidang meteorologi dan klimatologi seiring dengan meningkatnya kapasitas komputasi. Pendekatan ini mampu menemukan pola kompleks dari data deret waktu tanpa perlu asumsi statistik yang ketat (Rasp & Lerch, 2018). Dengan keunggulan tersebut, *machine learning* menjadi metode yang sangat potensial untuk menganalisis karakteristik fenomena atmosfer yang fluktuatif dan berubah secara dinamis.

Salah satu pendekatan *machine learning* yang mampu mempertahankan informasi jangka panjang serta adaptif dalam memodelkan hubungan non-linear dan kompleks pada data curah hujan adalah arsitektur berbasis *Recurrent Neural Network* (RNN), khususnya *Long Short-Term Memory* (LSTM) yang merupakan salah satu model dari rumpun *Deep Learning*. Model ini dirancang untuk menangani data deret waktu dengan ketergantungan temporal yang kuat melalui mekanisme *memory cell* dan *cell gate* (Goodfellow *et al.*, 2016; Hochreiter & Schmidhuber, 1997). Beberapa penelitian menunjukkan bahwa LSTM menghasilkan akurasi prediksi curah hujan yang lebih baik dibandingkan metode statistik konvensional (Akbar *et al.*, 2024; Ali *et al.*, 2024; Kratzert *et al.*, 2018). Selain itu, LSTM juga menghasilkan kinerja yang lebih baik dibandingkan *Random Forest* (RF) dalam prediksi curah hujan jangka panjang (41 tahun) di beberapa stasiun hujan di Turkey (Chen *et al.*, 2022). Meskipun demikian, kemampuan model dalam menangkap pola temporal dan hubungan non-linear curah hujan juga ditentukan oleh pemilihan fitur *input* atau prediktor yang berkaitan langsung dengan curah hujan.

Selain performa model, akurasi prediksi curah hujan juga ditentukan oleh pemilihan variabel prediktor yang representatif. Pola curah hujan muson di Jawa Tengah dipengaruhi oleh dinamika sirkulasi muson yang dapat direpresentasikan melalui angin pada lapisan 850 hPa (Kaparang & Hermawan, 2010). Komponen angin pada lapisan tersebut secara fisis berkaitan dengan variabilitas curah hujan di Indonesia (Wati *et al.*,


2023). Penelitian oleh Simanjuntak (2022) menunjukkan komponen angin zonal dan meridional lapisan 850 hPa terbukti berkontribusi terhadap fluktuasi curah hujan di wilayah Jawa. Selain faktor angin, ketersediaan uap air di atmosfer juga berperan penting dalam proses pembentukan awan dan terjadinya hujan (Ariyanti *et al.*, 2019). Penelitian oleh Aizansi *et al.* (2024) menguji performa LSTM dengan memanfaatkan beberapa prediktor termasuk komponen angin zonal, meridional, dan kelembapan relatif pada lapisan 850 hPa (RH850) lokal pada enam stasiun di Republik Benin, Afrika Barat.

Berdasarkan latar belakang yang telah diuraikan, penelitian ini bertujuan untuk mengevaluasi performa model LSTM dalam memprediksi curah hujan dasarian di Provinsi Jawa Tengah dengan prediktor angin zonal, angin meridional dan kelembapan relatif lapisan 850 hPa. Hasil penelitian ini diharapkan dapat memberikan informasi ilmiah mengenai kemampuan model dalam prediksi curah hujan serta menjadi referensi bagi penelitian selanjutnya dan mendukung pengambilan keputusan pada sektor yang berkaitan dengan informasi curah hujan.

II. METODE

A. Lokasi dan Data Penelitian

Wilayah kajian mencakup seluruh Provinsi Jawa Tengah yang terdiri atas 54 Zona Musim (ZOM) berdasarkan pemutakhiran ZOM periode normal 1991–2020 (BMKG, 2022). ZOM merupakan kawasan yang memiliki batas wilayah geografis tertentu dengan tipe pola curah hujan rata-rata yang relatif homogen, di mana terdapat perbedaan yang jelas antara periode musim hujan dan musim kemarau.



Gambar 1. Peta lokasi penelitian

Data yang digunakan meliputi data curah hujan dasarian hasil *blending* berbasis ZOM dari Bidang Analisis Variabilitas Iklim (AVI) Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) sebagai variabel

prediktan (target). Variabel prediktor atmosfer bersumber dari produk reanalisis ECMWF Reanalysis 5th Generation (ERA5) yang diterbitkan oleh European Centre for Medium-Range Weather Forecasts (ECMWF) dengan resolusi spasial $0,25^\circ \times 0,25^\circ$, meliputi angin zonal (U850), angin meridional (V850), dan kelembapan relatif (RH850) pada lapisan 850 hPa periode 1991–2024 dalam skala harian. Seluruh data yang digunakan memiliki tingkat kelengkapan data mencapai 100% (bebas dari *missing value*) selama periode rentang tahun 1991–2024. Rincian data disajikan pada **Tabel 1**.

Tabel 1. Rincian data penelitian

No	Data Penelitian	Satuan	Fungsi	Periode Data
1	Curah hujan hasil <i>blending</i> dasarian (ZOM)	mm	Prediktan	1991–2024
2	Angin zonal 850 hPa (U850) harian	m/s	Prediktor	1991–2024
3	Angin meridional 850 hPa (V850) harian	m/s	Prediktor	1991–2024
4	Kelembapan relatif 850 hPa (RH850) harian	%	Prediktor	1991–2024

B. Pra-Pemrosesan, Normalisasi, dan Pembagian Data

Data prediktor harian ERA5 yang diperoleh secara tahunan terlebih dahulu digabungkan menggunakan perangkat lunak *Climate Data Operator* (CDO) menjadi satu file NetCDF gabungan untuk masing-masing variabel prediktor pada seluruh periode (1991–2024). Tahap pra-pemrosesan selanjutnya dilakukan menggunakan Google Colab, meliputi ekstraksi nilai spasial berdasarkan batas poligon tiap ZOM (*intersect*) serta pengagregasian data harian menjadi rerata dasarian mengikuti pembagian dasarian I (tanggal 1–10), dasarian II (tanggal 11–20), dan dasarian III (tanggal 21 hingga akhir bulan) (BMKG, 2022). Seluruh variabel kemudian dinormalisasi menggunakan metode *Min–Max Normalization* untuk menyamakan skala data variabel prediktor dan prediktan (curah hujan), sehingga menghasilkan rentang nilai antara 0 hingga 1 (Han *et al.*, 2012). Parameter minimum dan maksimum dihitung hanya berdasarkan data latih (*training*) untuk mencegah kebocoran data (*data leakage*), yang kemudian diterapkan pada data validasi dan pengujian. Pembagian dataset dilakukan secara kronologis guna mempertahankan sifat dependensi temporal, yaitu data latih (1991–2015), data validasi (2016–2020), dan data uji (2021–2024).

C. Seleksi Fitur dengan LightGBM dan SHAP

Kontribusi relatif prediktor RH850, U850, dan V850 terhadap curah hujan dasarian dianalisis menggunakan *Light Gradient Boosting Machine* (LightGBM), yaitu metode *gradient boosting decision tree* yang memiliki keunggulan dalam efisiensi komputasi dan mampu menangani data dengan jumlah variabel yang besar (Ke *et al.*, 2017). Kontribusi setiap prediktor dinilai berdasarkan dua metrik yaitu *gain* yang menunjukkan besarnya pengurangan nilai *loss function* oleh fitur dan *split* yang menunjukkan seberapa sering fitur digunakan untuk membagi data pada *node*. Sebagai analisis lanjutan, interpretasi arah dan besar kontribusi setiap prediktor terhadap hasil prediksi dilakukan menggunakan *SHapley Additive exPlanations* (SHAP) dengan pendekatan *TreeSHAP* (Lundberg & Lee, 2017). Analisis LightGBM dan SHAP dilakukan hanya menggunakan data *training* untuk mencegah *data leakage*. Prediktor dengan kontribusi *gain*, *split*, dan *mean absolute SHAP* yang secara konsisten menunjukkan tingkat kepentingan tinggi pada seluruh ZOM dipilih sebagai fitur *input* model, sesuai prinsip *feature selection* yang mempertahankan prediktor paling relevan dan informatif terhadap prediksi curah hujan (Hancock *et al.*, 2025).

D. Model Long Short-Term Memory (LSTM)

Model LSTM digunakan untuk memprediksi curah hujan dasarian berbasis deret waktu dengan memanfaatkan informasi temporal dari data historis dengan fitur *input* variabel prediktor terpilih berdasarkan hasil seleksi fitur *input*. Struktur LSTM terdiri atas *cell state* dan *hidden state* yang diperbarui melalui tiga mekanisme gerbang, yaitu *forget gate*, *input gate*, dan *output*, yang secara ringkas dirumuskan sebagai berikut (Gers *et al.*, 1999; Hochreiter & Schmidhuber, 1997):

1. *Forget Gate* (f_t): mengatur porsi informasi lama yang akan dibuang dari *cell state*:

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

2. *Input Gate* (i_t) & *Candidate Cell State* ($\tilde{c}_t$): mengatur penambahan informasi baru ke dalam *cell state*:

$$i_t = \sigma(W_i[h_{t-1}, z_t] + b_i), \tilde{c}_t = \tanh(W_c[h_{t-1}, z_t] + b_c) \quad (2)$$

3. *Cell State Update* (c_t): memperbarui status memori utama jaringan:

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (3)$$

4. *Output Gate* (o_t) & *Hidden State* (h_t): menentukan luaran memori yang diteruskan ke langkah waktu berikutnya:

$$o_t = \sigma(W_o[h_{t-1}, z_t] + b_o), h_t = o_t \odot \tanh(c_t) \quad (4)$$

Berdasarkan persamaan tersebut z_t merepresentasikan vektor fitur masukan pada waktu t (meliputi deret *lag* curah hujan dan prediktor terpilih), W dan b mewakili matriks bobot dan bias, σ merupakan fungsi aktivasi sigmoid, dan $\odot$ menunjukkan perkalian elemen demi elemen. Panjang input (*lookback window*) yang digunakan adalah 36 dasarian atau setara dengan satu tahun. Panjang input tersebut mencakup satu siklus tahunan curah hujan di Jawa Tengah yang memiliki pola musonal (Aldrian & Susanto, 2003).

E. Optimasi Hyperparameter dengan Optuna

Optimasi *hyperparameter* model LSTM dilakukan secara otomatis menggunakan *framework* Optuna dengan algoritma *Tree-structured Parzen Estimator* (TPE) berbasis *Bayesian Optimization*, yang lebih efisien dibandingkan *Grid Search* maupun *Random Search* konvensional (Akiba *et al.*, 2019). Proses optimasi, pemilihan *hyperparameter* pada ruang pencarian dilakukan secara selektif dengan memfokuskan pada parameter yang paling berpengaruh terhadap performa model, seperti jumlah *unit* LSTM, *learning rate*, dan *dropout* (Bengio, 2012). Ruang pencarian *hyperparameter* dan konfigurasi pelatihan disajikan pada **Tabel 2**.

Tabel 2. Konfigurasi *hyperparameter* model LSTM

Komponen Jaringan	Parameter	Nilai / Ruang Pencarian
<i>Input Sequence</i>	<i>Lookback window</i>	36
Pelatihan Model	<i>Batch size</i>	16
	<i>Epoch</i>	100
Optimasi <i>hyperparameter</i>	LSTM units (neurons)	16, 32, 64, 128
	<i>Dropout</i>	0,1 – 0,4
	<i>Learning Rate</i>	1e-2, 1e-3, 1e-4
	Jumlah <i>trial</i> Optuna	20 <i>trial</i>
Regularisasi	<i>Early stopping patience</i>	15
<i>Optimizer</i>	Adam	-
<i>Loss function</i>	MSE	-

Optuna memilih kombinasi *hyperparameter* secara adaptif, melatih model pada data *training*, kemudian mengevaluasi performa pada data validasi. Kombinasi *hyperparameter* dengan nilai *Mean Square Error* (MSE) validasi terendah dipilih sebagai konfigurasi terbaik dan digunakan untuk prediksi pada periode *testing*.

F. Evaluasi Kinerja Model

Kinerja model LSTM pada periode uji (2021–2024) dievaluasi menggunakan tiga metrik, yaitu *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE) koefisien korelasi (r), dan bias (*Mean Bias Error*), yang dirumuskan sebagai berikut (Wilks, 2011; Willmott & Matsuura, 2005):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (7)$$

$$\text{Bias} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i) \quad (8)$$


Evaluasi kinerja model diukur berdasarkan tingkat kesalahan, kesesuaian pola, dan kecenderungan bias. RMSE mengukur besar kesalahan prediksi, koefisien korelasi (r) mengukur kesesuaian pola antara hasil prediksi dan data aktual, sedangkan bias menunjukkan kecenderungan hasil prediksi *overestimate* atau *underestimate*. Dalam persamaan tersebut, y_i dan $\hat{y}_i$ masing-masing merupakan nilai curah hujan aktual dan hasil prediksi pada waktu ke- i . Pada persamaan korelasi, X_i dan Y_i masing-masing merupakan nilai prediksi dan aktual, sedangkan $\bar{X}$ dan $\bar{Y}$ merupakan nilai rata-ratanya, simbol n merupakan jumlah data yang digunakan dalam evaluasi.

III. HASIL DAN PEMBAHASAN

A. Seleksi Prediktor sebagai Fitur Input Model


Analisis bobot kepentingan (*feature importance*) dilakukan menggunakan LightGBM dan SHAP untuk mengidentifikasi prediktor yang paling relevan dalam menjelaskan variabilitas curah hujan dasarian di Jawa Tengah. Perangkingan prediktor pada LightGBM dilakukan berdasarkan metrik *gain* dan *split*, sedangkan SHAP digunakan untuk memperkuat interpretasi mengenai besarnya dan arah kontribusi masing-masing prediktor terhadap hasil prediksi.

Hasil analisis *feature importance* secara agregat menggunakan LightGBM pada **Gambar 2** menunjukkan bahwa RH850 menempati posisi paling dominan pada kedua metrik evaluasi, baik *gain* maupun *split*, yang mengindikasikan bahwa variabel RH850 memberikan pengaruh paling signifikan dalam mereduksi *error* dan paling sering digunakan sebagai parameter pemisah data. Komponen angin zonal (U850) berada pada posisi kedua dengan performa yang konsisten lebih baik dibandingkan angin meridional (V850). Implikasi dari rendahnya nilai kedua metrik tersebut pada variabel V850 menunjukkan bahwa prediktor tersebut memiliki kontribusi yang paling terbatas terhadap peningkatan akurasi prediksi maupun dalam frekuensi pemisahan data di dalam model LightGBM. Temuan ini sejalan dengan penelitian Simanjuntak (2022) yang menyatakan bahwa angin zonal memiliki pengaruh yang lebih dominan terhadap curah hujan dibandingkan komponen angin meridional.




Gambar 2. LightGBM feature importance: (a) *gain*, (b) *split*

Hasil *feature importance* LightGBM diperkuat oleh *SHAP summary plot* pada **Gambar 3**, yang menunjukkan RH850 sebagai prediktor paling berpengaruh dengan rentang nilai SHAP paling lebar secara agregat, yaitu sekitar -100 hingga 250. Dominasi titik merah pada sisi positif menunjukkan bahwa nilai RH850 yang tinggi cenderung meningkatkan estimasi curah hujan, sedangkan nilai rendah cenderung menurunkannya. Variabel U850 menunjukkan pola kontribusi positif yang cenderung serupa dengan RH850 dengan rentang nilai sedikit lebih rendah, yaitu sekitar -40 hingga 220. Sementara itu, V850 memiliki kontribusi paling rendah karena sebagian besar nilai SHAP terkonsentrasi di sekitar nol, meskipun terdapat beberapa *outlier* yang memanjang ke arah positif, sehingga sensitivitas model terhadap V850 relatif rendah.



Gambar 3. SHAP *summary plot* prediktor

Pola yang sama dan konsisten juga ditunjukkan pada distribusi nilai *gain*, *split*, dan *mean absolute SHAP* di seluruh 54 ZOM pada **Gambar 4**, di mana RH850 dan U850 secara konsisten memiliki nilai median yang lebih tinggi dibandingkan V850. Berdasarkan hasil tersebut, RH850 dan U850 dipilih sebagai fitur *input* model LSTM, sedangkan V850 dieliminasi karena kontribusinya yang secara konsisten paling rendah terhadap prediksi curah hujan pada seluruh wilayah kajian. Hal tersebut mengindikasikan bahwa sebagian besar informasi dinamika angin yang relevan terhadap curah hujan di wilayah kajian cenderung lebih terwakili oleh komponen angin zonal dibandingkan angin meridional.



Gambar 4. Distribusi nilai *feature importance* prediktor pada setiap ZOM: (a) *gain*, (b) *split*, (c) *mean absolute SHAP*

B. Performa Model LSTM dalam Prediksi Curah Hujan Dasarian

Berdasarkan hasil optimasi *hyperparameter* menggunakan Optuna, diperoleh kombinasi *hyperparameter* terbaik berdasarkan nilai *Mean Square Error* (MSE) terendah pada periode data validasi, yaitu dengan rincian konfigurasi *units* = 16, *dropout rate* = 0,275, *learning rate* = 0,0026, *lookback window* = 36, dan *batch size* = 16. Konfigurasi *hyperparameter* tersebut selanjutnya digunakan untuk menguji kinerja model dengan fitur *input* terpilih pada seluruh ZOM selama periode *testing*.

Ringkasan statistik deskriptif metrik evaluasi kinerja model LSTM pada seluruh ZOM di Jawa Tengah disajikan pada **Tabel 3**. Hasil evaluasi menunjukkan bahwa model memiliki nilai RMSE rata-rata sebesar 48,40 mm dan MAE rata-rata sebesar 35,30 mm, dengan nilai RMSE berkisar antara 27,70–76,47 mm dan MAE antara 19,41–55,63 mm. Sementara itu, koefisien korelasi rata-rata sebesar 0,71 dengan rentang 0,53–0,81 menunjukkan adanya variasi kinerja model pada tiap ZOM, meskipun secara umum model mampu mengikuti pola curah hujan observasi dengan cukup baik. Nilai bias rata-rata sebesar -3,00 mm dengan

median $-3,06$ mm menunjukkan kecenderungan model sedikit melakukan *underestimation*, dengan rentang bias keseluruhan antara $-17,27$ hingga $13,47$ mm.


Tabel 3. Ringkasan metrik evaluasi model prediksi pada seluruh ZOM di Jawa Tengah

Ukuran Statistik	RMSE (mm)	MAE (mm)	Koefisien Korelasi (r)	Bias (mm)
Rata-rata	48,40	35,30	0,71	-3,00
Maksimum	76,47	55,63	0,81	13,47
Minimum	27,70	19,41	0,53	-17,27
Median	47,12	35,69	0,72	-3,06

Secara keseluruhan, model LSTM mampu merepresentasikan pola curah hujan dasarian dengan tingkat kesesuaian yang cukup baik, sebagaimana ditunjukkan oleh korelasi rata-rata 0,71 dan bias rata-rata yang relatif kecil. Namun, rentang nilai RMSE dan korelasi tiap ZOM menunjukkan bahwa performa model masih terdapat perbedaan cukup signifikan pada masing-masing wilayah, sehingga diperlukan analisis lebih lanjut secara spasial pada setiap ZOM.

C. Distribusi Spasial Performa Model LSTM


Analisis distribusi spasial dilakukan untuk mengidentifikasi performa model LSTM pada 54 ZOM di Provinsi Jawa Tengah berdasarkan metrik evaluasi RMSE, korelasi, dan bias. Analisis ini bertujuan untuk mengidentifikasi perbedaan tingkat akurasi model pada setiap ZOM. Selain itu, distribusi spasial performa model memungkinkan identifikasi keterkaitan antara tingkat akurasi model dengan karakteristik wilayah, seperti topografi, kedekatan dengan pesisir, dan kondisi atmosfer lokal yang mempengaruhi pola curah hujan.



Gambar 5. Distribusi spasial nilai RMSE pada setiap ZOM


Distribusi spasial nilai RMSE pada **Gambar 5** menunjukkan adanya variasi tingkat kesalahan prediksi pada setiap ZOM, dengan nilai tertinggi sebesar $76,47$ mm pada ZOM 258 dan terendah sebesar $27,70$ mm pada ZOM 262. Kesalahan prediksi cenderung lebih tinggi di sebagian wilayah Jawa Tengah bagian tengah, jika ditinjau berdasarkan **Gambar 1**, umumnya wilayah tersebut didominasi oleh dataran tinggi dan pegunungan. Sebaliknya, wilayah pesisir cenderung menunjukkan nilai RMSE yang lebih rendah. Pola tersebut mengindikasikan bahwa perbedaan karakteristik geografis dan topografi antarzona dapat berkaitan

dengan variasi kinerja model LSTM, sehingga tingkat kesalahan prediksi tidak seragam di seluruh wilayah Jawa Tengah.




Gambar 6. Distribusi spasial nilai MAE pada setiap ZOM

Distribusi spasial nilai MAE pada **Gambar 6** menunjukkan besarnya kesalahan absolut hasil prediksi curah hujan model LSTM pada setiap ZOM di Jawa Tengah. ZOM 227 memiliki nilai MAE tertinggi sebesar 55,63 mm, sedangkan ZOM 262 memiliki nilai MAE terendah sebesar 19,41 mm. Secara spasial, nilai MAE yang relatif tinggi cenderung tersebar di wilayah Jawa Tengah bagian tengah hingga barat. Sebaliknya, wilayah timur didominasi oleh nilai MAE yang lebih rendah. Pola distribusi spasial MAE sejalan dengan distribusi spasial RMSE, di mana wilayah dengan nilai MAE yang tinggi juga cenderung memiliki nilai RMSE yang tinggi. Nilai RMSE pada beberapa wilayah lebih tinggi dibandingkan MAE karena RMSE memberikan penalti lebih besar terhadap galat bernilai besar melalui proses pengkuadratan, sehingga kesalahan prediksi yang besar memberikan pengaruh lebih besar terhadap nilai RMSE.



Gambar 7. Distribusi spasial nilai korelasi pada setiap ZOM

Distribusi spasial nilai korelasi antara hasil prediksi LSTM dan data aktual pada **Gambar 7** menunjukkan variasi kinerja model setiap ZOM, dengan nilai tertinggi sebesar 0,81 pada ZOM 257 dan terendah sebesar 0,53 pada ZOM 220. Korelasi relatif tinggi mendominasi sebagian besar wilayah Jawa Tengah, sedangkan nilai lebih rendah cenderung terdapat di pesisir utara bagian tengah, sebagian wilayah barat daya, dan kawasan timur. Pola tersebut menunjukkan bahwa kemampuan LSTM dalam merepresentasikan variasi temporal curah hujan berbeda antarlokasi, yang dapat berkaitan dengan perbedaan karakteristik curah hujan dan kondisi geografis masing-masing ZOM. Secara umum, model mampu menangkap pola temporal curah hujan dengan cukup baik pada sebagian besar wilayah.



Gambar 8. Distribusi spasial nilai bias pada setiap ZOM


Distribusi spasial nilai bias hasil prediksi curah hujan model LSTM pada **Gambar 8** menunjukkan variasi pada setiap ZOM, dengan nilai bias tertinggi sebesar 13,47 mm pada ZOM 235 dan nilai terendah sebesar -17,27 mm pada ZOM 243. Secara geografis, bias negatif mendominasi sebagian besar wilayah Jawa Tengah, terutama di wilayah tengah, sedangkan bias positif hanya terlihat pada beberapa wilayah di bagian barat, utara, dan timur. Pola tersebut menunjukkan bahwa model LSTM cenderung menghasilkan prediksi curah hujan yang lebih rendah dibandingkan data aktual pada sebagian besar wilayah, sementara pada beberapa wilayah lainnya model menghasilkan prediksi yang sedikit lebih tinggi dari data aktualnya. Secara umum, sebagian besar ZOM memiliki nilai bias yang mendekati nol, dengan bias terkecil paling mendekati nol terdapat pada ZOM 263 dan ZOM 245 sebesar -0,13 mm.

D. Analisis Deret Waktu Perbandingan Curah Hujan Prediksi dan Aktual

Berdasarkan hasil evaluasi kinerja model pada seluruh ZOM, dilakukan analisis lebih lanjut melalui visualisasi deret waktu pada ZOM representatif. ZOM 257 dipilih sebagai representasi karena memiliki nilai korelasi tertinggi, yaitu 0,81, sehingga dapat menggambarkan kemampuan model dalam merepresentasikan pola temporal curah hujan. Analisis ini bertujuan untuk memberikan gambaran visual rinci mengenai kemampuan model LSTM dalam merepresentasikan pola dan fluktuasi curah hujan dari waktu ke waktu.

Gambar 9 menunjukkan perbandingan antara data aktual dan hasil prediksi curah hujan pada ZOM 257. Berdasarkan **Gambar 1**, ZOM 257 secara geografis terletak di wilayah pesisir utara Jawa. Secara umum, hasil prediksi model LSTM mampu mengikuti pola musiman dan fluktuasi curah hujan dengan cukup baik, yang ditunjukkan oleh nilai korelasi sebesar 0,81 sebagai nilai tertinggi dibandingkan ZOM lainnya. Nilai tersebut menunjukkan kesesuaian yang kuat antara pola perubahan curah hujan observasi dan hasil prediksi. LSTM memiliki keunggulan dalam mempelajari pola temporal dan musiman dari data curah hujan, sehingga

pada wilayah yang pola curah hujannya mengikuti karakteristik musiman yang jelas dan konsisten, model mampu menghasilkan prediksi dengan kesesuaian tinggi terhadap data aktual (Chao *et al.*, 2018). Model juga mampu mengikuti variasi pada periode curah hujan rendah, tetapi masih menunjukkan keterbatasan dalam menangkap lonjakan curah hujan ekstrem hingga sekitar 400 mm. Kondisi tersebut tercermin dari nilai RMSE sebesar 63,47 mm dan MAE sebesar 36,68 mm, sementara bias sebesar -12,11 mm menunjukkan adanya kecenderungan *underestimate*, terutama pada periode dengan curah hujan tinggi.



Gambar 9. Perbandingan curah hujan aktual dan prediksi ZOM 257

E. Pembahasan

Hasil analisis nilai *feature importance* melalui algoritma LightGBM dan evaluasi SHAP menunjukkan konsistensi yang baik dalam menjelaskan kelembapan relatif (RH850) sebagai prediktor paling dominan. Posisi kedua ditempati oleh angin zonal (U850), sedangkan komponen angin meridional (V850) memberikan kontribusi yang paling rendah. Hasil ini menunjukkan bahwa informasi kelembapan relatif lebih informatif dibandingkan informasi angin dalam merepresentasikan variasi curah hujan. Keterkaitan RH850 dan U850 dengan proses fisis pembentukan dan distribusi hujan menjadi dasar pemilihan kedua prediktor tersebut sebagai fitur *input* model LSTM. Penggunaan LightGBM dan SHAP dalam penelitian ini sejalan dengan Malakouti (2025) yang menunjukkan bahwa kombinasi kedua metode tersebut dapat digunakan untuk mengidentifikasi tingkat kepentingan prediktor sekaligus memberikan interpretasi terhadap arah dan besarnya kontribusi setiap fitur terhadap prediksi curah hujan.

Berdasarkan analisis performa model secara spasial, nilai RMSE dan MAE cenderung lebih tinggi pada ZOM bagian tengah Jawa Tengah yang berdasarkan topografi pada Gambar 1 memiliki elevasi lebih tinggi (dataran tinggi). Menurut Qian (2008), sirkulasi lokal seperti angin darat-laut dan angin gunung-lembah yang dipengaruhi topografi turut mempengaruhi variasi hujan, sehingga korelasi pada beberapa ZOM dapat lebih rendah meskipun nilai *error* hasil prediksinya relatif kecil. Kondisi tersebut dapat berkaitan dengan kecenderungan nilai *error* yang lebih tinggi pada ZOM bagian tengah dibandingkan wilayah pesisir. Nilai bias hasil prediksi pada sebagian besar ZOM menunjukkan bahwa hasil prediksi masih cenderung *underestimate*.

Analisis deret waktu hasil prediksi pada ZOM terpilih menunjukkan bahwa perbedaan karakteristik curah hujan mempengaruhi keseimbangan antara *error* dan korelasi model. Intensitas dan variasi curah hujan yang relatif rendah dapat menghasilkan *error* yang kecil, tetapi kejadian hujan ekstrem yang jarang lebih sulit ditangkap model menyebabkan nilai *error* yang besar. Kondisi tersebut sejalan dengan penelitian Park *et al.* (2025) yang menyatakan bahwa *loss* MSE pada LSTM cenderung mempelajari pola dominan pada data *training*, sehingga model cenderung kurang mampu merepresentasikan kejadian ekstrem yang jarang muncul pada periode *training*. Pada periode curah hujan ekstrem hingga sekitar 400 mm pada ZOM 257 dapat meningkatkan RMSE secara signifikan meskipun nilai korelasi prediksinya paling tinggi dibandingkan ZOM lainnya.s

Karakteristik curah hujan monsunial di Jawa Tengah, dengan satu puncak musim hujan yang jelas (Aldrian & Susanto, 2003), menyebabkan pola temporal yang relatif teratur dan tercermin pada nilai korelasi model LSTM yang secara umum cukup baik, dengan rata-rata sebesar 0,71 pada seluruh ZOM. Pola musiman yang teratur memberikan struktur temporal yang relatif mudah dipelajari oleh LSTM. Hal tersebut sejalan dengan hasil penelitian Akbar *et al.* (2024) yang menunjukkan bahwa LSTM mampu menangkap tren umum dan pola musiman pada data curah hujan. Selain dari faktor internal model, performa prediksi model juga dipengaruhi oleh pemilihan prediktor sebagai fitur *input* (Waqas *et al.*, 2024). Penggunaan prediktor lokal dalam penelitian ini memungkinkan sebagian variasi curah hujan yang dipengaruhi oleh faktor iklim lain belum sepenuhnya dapat direpresentasikan dengan baik oleh model.

Berdasarkan hasil evaluasi secara umum, implementasi model LSTM menunjukkan kemampuan dalam menangkap pola musiman curah hujan di Jawa Tengah dengan baik. Meskipun demikian, estimasi terhadap kejadian curah hujan ekstrem masih memerlukan pengembangan pada aspek pemodelan. Peningkatan performa dapat dilakukan melalui optimasi parameter internal dan penambahan fitur *input* pada model prediksi agar hasil prediksi lebih responsif terhadap lonjakan curah hujan dan pola fluktuatif di Jawa Tengah.

IV. PENUTUP

A. Simpulan

Berdasarkan hasil penelitian ini, model LSTM dengan fitur *input* RH850 dan U850 yang diperoleh melalui seleksi LightGBM dan SHAP serta konfigurasi *hyperparameter* terbaik hasil optimasi menunjukkan kinerja yang cukup baik dalam memprediksi curah hujan dasarian pada 54 ZOM di Provinsi Jawa Tengah. Model menghasilkan korelasi rata-rata sebesar 0,71 dengan kisaran 0,53–0,81, RMSE rata-rata 48,40 mm dengan kisaran 27,70–76,47 mm, dan MAE rata-rata 35,30 mm dengan kisaran 19,41–55,63 mm. Performa model bervariasi pada setiap ZOM yang diduga berkaitan dengan pola curah hujan dan karakteristik geografis wilayah. Nilai *error* prediksi cenderung lebih tinggi pada beberapa ZOM di bagian tengah Jawa Tengah yang umumnya didominasi wilayah dataran tinggi dan pegunungan, dibandingkan dengan ZOM di wilayah pesisir.

Secara umum, model LSTM mampu mengikuti pola umum curah hujan, tetapi masih kurang mampu merepresentasikan puncak, lembah, dan perubahan curah hujan yang terjadi secara cepat. Keterbatasan tersebut juga terlihat pada kemampuan model dalam menangkap kejadian hujan ekstrem, dengan kecenderungan *underestimate* pada sebagian besar ZOM yang ditunjukkan oleh bias rata-rata sebesar –3,00 mm dengan kisaran –17,27 hingga 13,47 mm. Meskipun demikian, kemampuan model dalam mengikuti pola umum dan variasi musiman curah hujan dasarian menunjukkan potensinya sebagai informasi pendukung prediksi curah hujan dasarian di Provinsi Jawa Tengah. Pengembangan lebih lanjut diperlukan untuk meningkatkan kemampuan model dalam menangkap perubahan cepat dan kejadian hujan ekstrem.

B. Saran

Hasil penelitian ini menunjukkan masih terdapat beberapa aspek yang dapat dikembangkan pada penelitian selanjutnya. Penambahan model pembanding seperti *Gated Recurrent Unit* (GRU), *Random Forest* (RF) ataupun model lainnya dapat dilakukan untuk memperoleh evaluasi performa yang lebih komprehensif. Selain itu, perlu dipertimbangkan penambahan prediktor lain di luar angin zonal, angin meridional, dan kelembapan relatif lapisan 850 hPa, baik yang bersifat atmosfer lokal maupun skala regional yang diharapkan dapat meningkatkan akurasi prediksi model. Model LSTM dapat dimanfaatkan sebagai informasi pendukung prediksi curah hujan dasarian, terutama di wilayah pesisir Jawa Tengah. Pengembangan model lebih lanjut diperlukan pada wilayah bagian tengah untuk mengantisipasi kecenderungan *underestimate* pada curah hujan tinggi.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Sekolah Tinggi Meteorologi Klimatologi dan Geofisika (STMKG) atas dukungan yang diberikan selama pelaksanaan penelitian. Ucapan terima kasih juga

disampaikan kepada Bidang Analisis Variabilitas Iklim (AVI), Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) atas dukungan data yang digunakan dalam penelitian ini serta dukungan informasi yang menunjang pelaksanaan penelitian.

DAFTAR PUSTAKA

- Aeni, P., & Muhammad, K. A. (2024). *Hydrometeorological disaster: Challenges and mitigation in Indonesia*. 5(1), 318–330. <https://doi.org/10.59141/jist.v5i01.888>
- Aizansi, A. N., Ogunjobi, K. O., & Ogou, F. K. (2024). Monthly rainfall prediction using artificial neural network (case study: Republic of Benin). *Environmental Data Science*, 3, 1–25. <https://doi.org/10.1017/eds.2024.10>
- Akbar, A. A., Darmawan, Y., Wibowo, A., & Rahmat, H. K. (2024). Accuracy assessment of monthly rainfall predictions using seasonal ARIMA and long short-term memory (LSTM). *Journal of Computer Science and Engineering (JCSE)*, 5(2), 99–114. <http://icsejournal.com/index.php/>
- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). *Optuna: A next - generation hyperparameter optimization framework*. 1–10.
- Aldrian, E., & Susanto, D. R. (2003). Identification of three dominant rainfall regions within Indonesia and their relationship to sea surface temperature. *International Journal of Climatology*, 1452, 1435–1452. <https://doi.org/10.1002/joc.950>
- Ali, M. E., Shil, P., Shakib, M. S., Chanda, A., Khisa, R., Baten, M. A., & Mayoa, F. (2024). A comparative analysis of rainfall forecasting in Cox's Bazar using SARIMA, LSTM and GRU. *International Conference on Computer and Information Technology, ICCIT 2024 - Proceedings, December*, 2671–2676. <https://doi.org/10.1109/ICCIT64611.2024.11021778>
- Ariyanti, R. D., Sugihartati, F. M., Rethataranita, W., & Winarso, P. A. (2019). Uji Keakuratan Data GFS menggunakan Model WRF-ARW pada Siklon Tropis Flamboyan. *Jurnal Ilmu Dan Inovasi Fisika*, 3(2), 62–74. <https://doi.org/10.24198/jiif.v3i2.23149>
- Bengio, Y. (2012). Practical recommendations for gradient-based training of deep architectures. *ArXiv*.
- BMKG. (2022). *Buku Pemutakhiran Zona Musim Indonesia Periode 1991-2020*. Jakarta: Badan Meteorologi Klimatologi dan Geofisika (BMKG)
- BNPB. (2025). *Data Bencana Indonesia 2024*. Pusat Data Informasi dan Komunikasi Kebencanaan Badan Nasional Penanggulangan Bencana.
- BPS. (2025). *Luas Panen dan Produksi Padi 2024 Provinsi Jawa Tengah*. Badan Pusat Statistik Provinsi Jawa Tengah. Retrieved from <https://jateng.bps.go.id/id/statistics-table/3/WmpaNk1YbGFjR0pOUjBKYWFIQIBSU3MwVHpOVWR6MDkjMw==/luas-panen--produktivitas--dan-produksi-padi-menurut-kabupaten-kota-di-provinsi-jawa-tengah--2024.html?year=2024>
- Chao, Z., Pu, F., Yin, Y., Han, B., & Chen, X. (2018). Research on real-time local rainfall prediction based on MEMS sensors. *Journal of Sensors*, 2018. <https://doi.org/10.1155/2018/6184713>
- Chen, C., Zhang, Q., Kashani, M. H., Jun, C., Sayed, M., Band, S. S., Dash, S. S., & Chau, K. (2022). *Forecast of rainfall distribution based on fixed sliding window long short-term memory*. 2060. <https://doi.org/10.1080/19942060.2021.2009374>
- Ejike, O., & Ndzi, D. (2025). Comparative study of machine learning-based rainfall prediction in tropical and temperate climates. *Climate*, 1–27.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (1999). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 1–19.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

- Hadibasyir, H. Z., Kurniawan, R., & Atika, R. (2015). Pemanfaatan Citra SRTM V3 dengan Teknik Analisis Zona untuk Mengkaji Keterkaitan Curah Hujan dengan Topografi di Wilayah Provinsi Jawa Tengah dan Daerah Istimewa Yogyakarta. 345–350.
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques* (3rd ed.). Morgan Kaufmann.
- Hancock, J. T., Khoshgoftaar, T. M., & Liang, Q. (2025). A problem-agnostic approach to feature selection and analysis using SHAP. *Journal of Big Data*, 12(1), 1–22. <https://doi.org/10.1186/s40537-024-01041-1>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- Kaparang, N. E., & Hermawan, E. (2010). Analisis Perilaku Angin di Lapisan 850 hPa Hasil Observasi Data WPR Dikaitkan Dengan Perilaku Data Indeks Monsun Global di Indonesia. *Jurnal Sains Dirgantara*, 8, 1–24.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T. (2017). *LightGBM: A highly efficient gradient boosting decision tree*. 1–9.
- Kratzert, F., Klotz, D., Brenner, C., Schulz, K., & Herrnegger, M. (2018). *Rainfall-runoff modelling using long short-term memory (LSTM) networks*. 1–30.
- Kurniyaningrum, E., Rianti, A., Herlina, L., Victorya, C., Wahan, Nyimas, Hazel, L., Assidik, M. L., Faisal, U. F., Kawanda, A., & Saily, R. (2025). Pendekatan Statistik Klasifikasi Curah Hujan Dalam Pengelolaan Sumber Daya Air Berkelanjutan. *Journal of Infrastructure and Civil Engineering*, 5(3), 205–213.
- Lundberg, S. M., & Lee, S. (2017). *A Unified Approach to Interpreting Model Predictions. Section 2*, 1–10.
- Malakouti, S. M. (2025). Leveraging shapley additive explanations (SHAP) and fuzzy logic for efficient rainfall forecasts. *Scientific Reports*, 15(1), 1–25. <https://doi.org/10.1038/s41598-025-22081-4>
- Mamenun, Pawitan, H., & Sophaheluwakan, A. (2014). Validasi dan Koreksi Data Satelit TRMM Pada Tiga Pola Hujan di Indonesia. *Jurnal Meteorologi Dan Geofisika*, 15(1), 13–23.
- Mhatre, N., & Cooley, D. (2024). Transformed-linear models for time series extremes. *Journal of Time Series Analysis*, 45(5), 671–690. <https://doi.org/10.1111/jtsa.12732>
- Park, Y., Liu, X., Zhu, Y., & Hong, Y. (2025). Using entity-aware LSTM to enhance streamflow predictions in transboundary and large lake basins. *Hydrology*, 12(10), 1–26. <https://doi.org/10.3390/hydrology12100261>
- Qian, J. H. (2008). Why precipitation is mostly concentrated over islands in the maritime continent. *Journal of the Atmospheric Sciences*, 65(4), 1428–1441. <https://doi.org/10.1175/2007JAS2422.1>
- Rasp, S., & Lerch, S. (2018). *Neural networks for postprocessing ensemble weather forecasts*. 3885–3900. <https://doi.org/10.1175/MWR-D-18-0187.1>
- Satyawardhana, H., & Yulihastin, E. (2016). Interaksi El-Nino, Monsun dan Topografi Lokal terhadap Anomali Curah Hujan di Pulau Jawa. *Pusat Sains Dan Teknologi Atmosfer, LAPAN*, 59–74.
- Simanjuntak, P. P. (2022). Komponen Angin Zonal dan Meridional sebagai Prekursor Penentu Awal Musim serta Pengaruh ENSO Terhadap Variasinya. *Prisma Fisika*, 10(3), 371–376. <https://doi.org/10.26418/pf.v10i3.59057>
- Waqas, M., Humphries, U. W., Wangwongchai, A., Dechpichai, P., Zarin, R., & Hlaing, P. T. (2024). Incorporating novel input variable selection method for in the different water basins of Thailand. *Alexandria Engineering Journal*, 557–576. <https://doi.org/10.1016/j.aej.2023.11.046>
- Wati, T., Hadi, T. W., Sopaheluwakan, A., & Hutasoit, L. M. (2023). The study of wind field ERA-20C in Monsoon domains for rainfall predictor in Indonesia (Java, Sumatra, and Borneo). *Agromet*, 37(1), 34–43. <https://doi.org/10.29244/j.agromet.37.1.34-43>
- Wihardjaka, A., Pramono, A., & Sutriadi, M. T. (2020). Peningkatan Produktivitas Padi Sawah Tadah Hujan Melalui Penerapan Teknologi Adaptif Dampak Perubahan Iklim. *Jurnal Sumberdaya Lahan*, 14(1), 25. <https://doi.org/10.21082/jsdl.v14n1.2020.25-36>

- Wilks, D. S. (2011). *Statistical Methods in the Atmospheric Sciences* (3rd ed.). Academic Press.
- Willmott, C. J., & Matsuura, K. (2005). *Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance*. 30, 79–82.
- Yanfatriani, E., Marzuki, M., Vonnisa, M., Razi, P., Hapsoro, C. A., Ramadhan, R., & Yusnaini, H. (2024). *Extreme rainfall trends and hydrometeorological disasters in tropical regions: Implications for climate resilience*. 8(5), 1860–1874.