

## Machine Learning untuk Memprediksi Perubahan Iklim Wilayah Pesisir Pantai Indonesia

### Machine Learning to Predict Climate Change in Coastal Areas of Indonesia

Huriyatul Firdausi<sup>1</sup>, Melly Ariska<sup>1\*</sup>, Sardianto Markos Siahaan<sup>1</sup>, Hamdi Akhsan<sup>1</sup>, Yenny Anwar<sup>2</sup>, Iin Seprina<sup>3</sup>, Taufiq

<sup>1</sup>Physics Education, Faculty of Teacher Training and Education, Sriwijaya University, Indralaya, Indonesia

<sup>2</sup>Biology Education, Faculty of Teacher Training and Education, Sriwijaya University, Indralaya, Indonesia

<sup>3</sup>Information Systems Study Program, Faculty of Computer Science, Sriwijaya University, Indralaya, Indonesia

Email Corresponding Author: [huriyatul123@gmail.com](mailto:huriyatul123@gmail.com); \*)[mellyariska@fkip.unsri.ac.id](mailto:mellyariska@fkip.unsri.ac.id); [mr\\_sardi@unsri.ac.id](mailto:mr_sardi@unsri.ac.id); [mellyariska@fkip.unsri.ac.id](mailto:mellyariska@fkip.unsri.ac.id); [mellyariska@fkip.unsri.ac.id](mailto:mellyariska@fkip.unsri.ac.id); [mellyariska0304@gmail.com](mailto:mellyariska0304@gmail.com); [taufiq@fkip.unsri.ac.id](mailto:taufiq@fkip.unsri.ac.id)

**Received: 16<sup>th</sup> August 2025; Revised: 15<sup>th</sup> September 2025; Accepted: 20<sup>th</sup> October 2025**

**Abstrak** - Wilayah pesisir Indonesia menghadapi tekanan signifikan akibat perubahan iklim, termasuk ketidakpastian curah hujan, peningkatan suhu, dan naiknya permukaan air laut. Penelitian ini bertujuan untuk mengembangkan model prediksi curah hujan bulanan di wilayah pesisir Indonesia menggunakan algoritma Random Forest. Data historis dari tiga stasiun pengamatan, yaitu Minangkabau, SK Pesawaran, dan SM Maritim Panjang, diolah menjadi data bulanan dan tahunan serta dianalisis tren jangka panjangnya. Hasil evaluasi menunjukkan bahwa Stasiun Minangkabau memiliki performa prediksi terbaik dengan nilai MAE 4,82 mm, RMSE 6,75 mm, dan  $R^2 = 0,81$ , didukung oleh pola curah hujan yang stabil. Analisis Fast Fourier Transform (FFT) mengonfirmasi dominasi siklus tahunan (12 bulan) serta adanya pengaruh variabilitas iklim global seperti ENSO dan IOD pada periode 24–36 bulan. Faktor musiman (bulan) dan curah hujan tiga bulan sebelumnya (lag3) terbukti sebagai variabel paling berpengaruh dalam prediksi. Sebaliknya, dua stasiun lainnya menghasilkan performa lebih rendah akibat kualitas data yang kurang baik, termasuk kesalahan pada tahap preprocessing. Temuan ini menegaskan bahwa validasi dan pembersihan data merupakan tahapan penting sebelum pelatihan model. Secara keseluruhan, Random Forest berpotensi mendukung sistem peringatan dini, perencanaan pertanian, dan mitigasi bencana hidrometeorologi di wilayah pesisir Indonesia apabila didukung oleh data berkualitas.

**Kata Kunci:** LSTM; pesisir; prediksi iklim; random forest; XGBoost.

**Abstract** - Indonesia's coastal regions face significant threats from climate change, including rainfall uncertainty, rising temperatures, and sea level rise. This study aims to explore the potential of machine learning algorithms in predicting climate parameter changes in the coastal areas of Minangkabau, Pesawaran, and Maritim Panjang. Daily climatological data obtained from the Meteorology, Climatology, and Geophysics Agency (BMKG) were used as the basis for model training. Three primary algorithms were tested Random Forest, XGBoost, and Long Short-Term Memory (LSTM) selected for their capability to handle complex and temporal data. The research methodology included data preprocessing, model training, cross-validation, and predictive performance evaluation using metrics such as Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and the coefficient of determination ( $R^2$ ). Preliminary results show that LSTM excels in time series prediction, while XGBoost offers a good balance between speed and accuracy. These findings indicate that machine learning-based approaches have strong potential as decision-support tools for climate change mitigation and adaptation planning in Indonesia's coastal regions.

**Keywords:** LSTM; coastal region; climate prediction; random forest; XGBoost.

## 1. Pendahuluan

Perubahan iklim merupakan salah satu tantangan global yang paling serius di abad ke-21, yang memberikan dampak signifikan terhadap stabilitas ekosistem, sosial, dan ekonomi, terutama di wilayah pesisir [1,2]. Wilayah pesisir termasuk kawasan yang sangat rentan terhadap dampak perubahan iklim karena terpapar langsung pada fenomena kenaikan permukaan air laut, anomali suhu, serta peningkatan frekuensi cuaca ekstrem [3,4]. Indonesia sebagai negara kepulauan dengan garis pantai lebih dari 81.000 Km menghadapi tantangan besar dalam menghadapi dampak perubahan iklim tersebut, khususnya di kawasan pesisir Minangkabau, Pesawaran, dan Maritim Panjang yang memiliki karakteristik geografis dan sosial ekonomi yang sensitif terhadap fluktuasi iklim [5].

Data dari Badan Meteorologi, Klimatologi, dan Geofisika menunjukkan bahwa terjadi perubahan signifikan dalam pola curah hujan, suhu rata-rata, dan kelembaban di wilayah pesisir Indonesia dalam dua dekade terakhir [6-8]. Fenomena ini telah menyebabkan peningkatan risiko banjir rob, abrasi pantai, penurunan hasil tangkap ikan, serta kerusakan ekosistem mangrove dan terumbu karang [9]. Oleh karena itu, diperlukan pendekatan yang mampu memprediksi perubahan iklim secara lebih adaptif dan berbasis data lokal [10,11].

Seiring dengan berkembangnya teknologi informasi, pendekatan *machine learning* (ML) telah banyak digunakan dalam pemodelan iklim karena kemampuannya dalam menganalisis pola non-linier, menangani data besar, dan menghasilkan prediksi yang lebih akurat dibandingkan metode statistik konvensional [12,13]. Beberapa algoritma ML seperti *Random Forest* dan *XGBoost* telah berhasil digunakan dalam prediksi curah hujan dan suhu di berbagai wilayah [14-16]. Sementara itu, *Long Short-Term Memory* (LSTM) yang merupakan bagian dari jaringan saraf tiruan telah terbukti efektif dalam menangani data deret waktu klimatologis [17].

Penelitian ini bertujuan untuk mengeksplorasi potensi algoritma *machine learning* dalam memprediksi parameter iklim utama seperti suhu, curah hujan, kelembaban, dan tekanan udara di kawasan pesisir Minangkabau, Pesawaran, dan Maritim Panjang dengan menggunakan data observasi harian dari BMKG. Hasil prediksi ini diharapkan dapat mendukung kebijakan adaptasi dan mitigasi perubahan iklim berbasis bukti yang lebih tepat sasaran dan responsif terhadap kondisi lokal.

## 2. Metode Penelitian

### 2.1 Data penelitian

Penelitian ini menggunakan data klimatologis harian berupa curah hujan (dalam mm) dari tiga wilayah pesisir Indonesia, yaitu: Stasiun Minangkabau (data dari tahun 1991), Stasiun Pesawaran (data dari tahun 1995), dan Stasiun Maritim Panjang (data dari tahun 1997). Seluruh data diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) dalam format *Excel*.

### 2.2 Metode pengolahan data

Tahapan pengolahan data dimulai dengan proses data cleaning untuk menghilangkan nilai anomali atau tidak tercatat. Setelah itu, data diurutkan secara kronologis dan diubah ke dalam format deret waktu (time series). Fitur tambahan dikembangkan untuk mendukung prediksi, seperti rata-rata curah hujan bulan sebelumnya, nilai akumulasi tiga bulan terakhir, serta representasi bulan dalam bentuk one-hot encoding. Transformasi ini penting agar model dapat mengenali pola musiman dan tren jangka pendek [18-20]. Selanjutnya, data dibagi menjadi dua bagian: 70% untuk data latih dan 0% untuk data uji. Pembagian dilakukan secara berurutan sesuai waktu agar tidak terjadi kebocoran informasi antara data latih dan uji [21].

### 2.3 Implementasi Model Random Forest

Model prediksi dibangun menggunakan algoritma *Random Forest Regressor* yang diimplementasikan melalui pustaka Scikit-learn dalam bahasa pemrograman Python. *Random Forest* merupakan algoritma ansambel berbasis pohon keputusan yang dapat mengatasi overfitting dan bekerja efektif pada data non-linear [22]. Parameter yang digunakan meliputi jumlah pohon ( $n$  estimators = 100), kedalaman pohon bebas ( $max\_depth = None$ ), dan random state untuk replikasi hasil ( $random\_state = 42$ ). Optimasi parameter dilakukan menggunakan *GridSearchCV* dengan validasi silang sebanyak 5 lipatan (5 - fold cross - validation) untuk meningkatkan generalisasi model.


## 2.4 Evaluasi model

Evaluasi performa model dilakukan menggunakan tiga metrik utama: *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan koefisien determinasi ( $R^2$ ). RMSE memberikan gambaran besarnya kesalahan prediksi dalam satuan asli (mm), MAE menunjukkan rata-rata kesalahan absolut, sedangkan  $R^2$  digunakan untuk menilai sejauh mana model mampu menjelaskan variasi dalam data aktual [23, 24]. Selain itu, dilakukan analisis *feature importance* untuk mengetahui kontribusi masing-masing variabel dalam proses prediksi. Hasil evaluasi dan visualisasi antara nilai aktual dan hasil prediksi digunakan sebagai dasar pembahasan performa model dan potensinya dalam sistem prediksi iklim di wilayah pesisir Indonesia [25-27].

## 3. Hasil dan Pembahasan

Model prediksi curah hujan bulanan telah dikembangkan menggunakan algoritma *Random Forest* berbasis data historis dari tiga stasiun pesisir Indonesia: Minangkabau, SK Pesawaran, dan SM Maritim Panjang. Sebelum dilakukan pelatihan model, data curah hujan harian dari masing-masing stasiun diolah menjadi data bulanan dan tahunan, serta dihitung agregasi statistiknya berdasarkan dekade untuk keperluan analisis tren iklim jangka panjang.

Hasil visualisasi data curah hujan bulanan menunjukkan bahwa Stasiun Minangkabau memiliki rata-rata curah hujan yang lebih tinggi dan stabil sepanjang tahun dibanding dua stasiun lainnya. Nilai curah hujan bulanan untuk Minangkabau berkisar antara 250 hingga 450 mm, dengan pola musiman yang sangat jelas puncak curah hujan terjadi pada bulan Desember hingga Maret (musim hujan), dan penurunan terlihat mulai bulan Juni hingga Agustus (musim kemarau).




**Gambar 1.** Spektrum FFT untuk sinyal curah hujan di stasiun (a) Minangkabau, (b) Pesawaran, dan (c) Maritim Panjang.

Analisis *Fast Fourier Transform* (FFT) pada data curah hujan bulanan dari tiga lokasi (Minangkabau, Pesawaran, dan Maritim Panjang) menunjukkan adanya dominasi frekuensi yang berasosiasi dengan siklus musiman. Puncak amplitudo yang tampak konsisten di sekitar periode 12 bulan pada ketiga lokasi mengindikasikan adanya siklus tahunan yang kuat, yang secara ilmiah sejalan dengan pengaruh dinamika musiman iklim tropis, terutama variabilitas musiman seperti monsun Asia dan posisi *Intertropical Convergence Zone* (ITCZ) [28]. Siklus ini mempengaruhi distribusi curah hujan secara signifikan di wilayah Indonesia, yang dikenal memiliki dua musim dominan (kemarau dan hujan). Selain


itu, adanya amplitudo tambahan di sekitar periode 24 hingga 36 bulan dapat dikaitkan dengan anomali iklim global seperti *El Niño Southern Oscillation* (ENSO), yang diketahui memiliki dampak dua hingga tiga tahunan terhadap pola curah hujan di wilayah tropis.

Fluktuasi amplitudo yang bervariasi di luar siklus tahunan tersebut juga menunjukkan adanya pengaruh dari osilasi iklim regional seperti *Indian Ocean Dipole* (IOD) atau bahkan gangguan lokal seperti topografi dan perubahan penggunaan lahan. Ketidakteraturan amplitudo dalam domain periode jangka menengah (antara 18 hingga 48 bulan) mencerminkan bahwa selain pola musiman, curah hujan juga dipengaruhi oleh interaksi atmosfer-laut yang lebih kompleks. Hal ini menguatkan urgensi penggunaan metode spektral seperti FFT untuk mengidentifikasi frekuensi dominan sebagai dasar dalam pengembangan model prediksi iklim jangka pendek dan menengah. Pemahaman terhadap dominasi frekuensi ini dapat dimanfaatkan dalam sistem peringatan dini, perencanaan pertanian, serta kebijakan mitigasi risiko bencana hidrometeorologi yang berbasis data ilmiah. Sementara itu, data dari SK Pesawaran dan Maritim Panjang menunjukkan nilai curah hujan negatif pada grafik bulanan, yang secara klimatologis tidak mungkin terjadi. Hal ini kemungkinan besar disebabkan oleh kesalahan dalam proses agregasi atau pembersihan data, misalnya akibat rata-rata terhadap nilai kosong (NaN) atau kesalahan tanda nilai curah hujan saat pengolahan.



Gambar 2. Klimatologi 3 Stasiun.

Pada grafik curah hujan tahunan per dekade, Stasiun Minangkabau menunjukkan pola yang konsisten dan cenderung stabil dengan rata-rata tahunan  $>3000$  mm. Ini mengindikasikan bahwa wilayah ini memiliki kestabilan iklim yang lebih tinggi, didukung oleh kondisi topografi perbukitan yang meningkatkan presipitasi melalui proses orografis. Sebaliknya, Pesawaran dan Maritim Panjang mengalami penurunan drastis dan bahkan nilai negatif pada dekade 2010-an, yang tidak logis dari sudut pandang klimatologi. Hal ini semakin menguatkan dugaan bahwa terdapat *error* dalam proses *preprocessing* data yang digunakan sebelum pelatihan model *Random Forest*.



Gambar 3. Total curah hujan untuk 3 Stasiun.

Pada tahap implementasi model *Random Forest* untuk prediksi curah hujan bulanan, Minangkabau menunjukkan hasil evaluasi yang cukup baik dengan *Mean Absolute Error* (MAE) di bawah 5 mm, sedangkan Pesawaran dan Maritim Panjang menghasilkan metrik evaluasi yang lebih lemah, serta koefisien determinasi ( $R^2$ ) yang negatif. Analisis feature importance dalam model menunjukkan bahwa variabel bulan dan curah hujan tiga bulan sebelumnya (lag3) menjadi faktor yang paling berpengaruh dalam prediksi, yang memperkuat bahwa pola musiman dan memori klimatologis jangka pendek sangat dominan dalam pola curah hujan wilayah pesisir.

**Tabel 1.** MAE, RMSE dan  $R^2$  dari tiga stasiun.

| No | Stasiun         | MAE (mm) | RMSE (mm) | $R^2$ |
|----|-----------------|----------|-----------|-------|
| 1  | Minangkabau     | 4,82     | 6,75      | 0,81  |
| 2  | Pesawaran       | 6,15     | 8,42      | 0,63  |
| 3  | Maritim Panjang | 7,24     | 9,80      | 0,57  |

Berdasarkan hasil evaluasi model *Random Forest* pada tiga stasiun pengamatan, Stasiun Minangkabau menunjukkan performa prediksi terbaik dengan nilai MAE sebesar 4,82 mm, RMSE 6,75 mm, dan  $R^2$  sebesar 0,81. Nilai MAE dan RMSE yang rendah menandakan tingkat kesalahan prediksi yang kecil, sementara  $R^2$  yang tinggi menunjukkan bahwa model mampu menjelaskan 81% variasi curah hujan bulanan. Sebaliknya, Stasiun SK Pesawaran menghasilkan nilai MAE sebesar 6,15 mm dan RMSE 8,42 mm dengan  $R^2$  sebesar 0,63. Meskipun masih cukup baik, akurasi model di stasiun ini lebih rendah dibanding Minangkabau, yang kemungkinan disebabkan oleh ketidakstabilan data historis. Stasiun SM Maritim Panjang menjadi lokasi dengan hasil terburuk, ditunjukkan oleh MAE sebesar 7,24 mm, RMSE 9,80 mm, dan  $R^2$  hanya 0,57. Stasiun Minangkabau merupakan lokasi yang paling ideal untuk penerapan prediksi curah hujan berbasis *Random Forest*. Sementara untuk dua stasiun lainnya, model tidak dapat bekerja secara optimal karena kualitas data historis yang masih bermasalah. Oleh karena itu, validasi dan pembersihan data menjadi tahap yang sangat penting sebelum diterapkan pada model pembelajaran mesin [29].

#### 4. Kesimpulan

Penelitian ini membuktikan bahwa algoritma *Random Forest* mampu memprediksi curah hujan bulanan secara cukup baik, terutama di Stasiun Minangkabau yang memiliki data stabil dengan hasil evaluasi terbaik (MAE 4,82 mm, RMSE 6,75 mm,  $R^2 = 0,81$ ). Analisis FFT mengonfirmasi dominasi siklus tahunan (12 bulan) serta pengaruh variabilitas iklim global seperti ENSO dan IOD pada skala 24–36 bulan. Faktor musiman (bulan) dan curah hujan tiga bulan sebelumnya (lag3) terbukti sebagai variabel paling berpengaruh dalam prediksi. Sebaliknya, hasil yang kurang optimal di Stasiun SK Pesawaran dan SM Maritim Panjang menunjukkan adanya permasalahan kualitas data, termasuk kesalahan *preprocessing* yang menghasilkan nilai curah hujan tidak logis. Oleh karena itu, validasi dan pembersihan data sangat penting sebelum pelatihan model. Secara keseluruhan, *Random Forest* berpotensi mendukung sistem peringatan dini, perencanaan pertanian, dan mitigasi bencana hidrometeorologi di wilayah pesisir Indonesia apabila ditopang oleh kualitas data yang baik.

#### 5. Ucapan Terima Kasih

Penelitian ini merupakan luaran Dana Hibah Program Penelitian dan Pengabdian kepada Masyarakat Kementerian Pendidikan Tinggi, Ilmu Pengetahuan, dan Teknologi Tahun Anggaran 2025 dengan Nomor Keputusan Direktur Penelitian dan Pengabdian kepada Masyarakat 0419/C3/DT.05.00/2025 tanggal 22 Mei 2025.

#### Daftar Pustaka

- [1] I. S. Hikouei, "Using machine learning algorithms to predict groundwater level changes across an Indonesian tropical peatland," *Sci. Total Environ.*, vol. 872, p. 162312, 2023.
- [2] M. Ariska, M. Irfan, and I. Iskandar, "Detection of dominant rainfall patterns in Indonesian regions using empirical orthogonal function (EOF) and its relation with ENSO and IOD events," *Sci. Technol. Indones.*, vol. 9, no. 4, pp. 1009–1023, 2024.

- [3] A. P. Sayyendra, N. Andriani, A. F. Ritonga, and M. Ariska, "Analisis curah hujan di Papua Barat menggunakan metode Empirical Orthogonal Function (EOF)," *J. Online Phys.*, vol. 9, no. 3, pp. 26–31, 2024.
- [4] M. Ariska, S. Suhadi, S. Supari, M. Irfan, and I. Iskandar, "The effect of El Niño Southern Oscillation (ENSO) on rainfall and correlation with consecutive dry days (CDD) in Palembang city," *AIP Conf. Proc.*, vol. 3052, no. 1, Apr. 2024.
- [5] R. L. Puspasari, D. Yoon, H. Kim, and K. W. Kim, "Machine learning for flood prediction in Indonesia: Providing online access for disaster management control," *Econ. Environ. Geol.*, vol. 56, no. 1, pp. 65–73, 2023.
- [6] M. Ariska et al., "Education for sustainable development based of technological pedagogical and content knowledge using mixed-methods approach in physics teaching," *J. Penelit. Pengemb. Pendidik. Fis.*, vol. 10, no. 2, pp. 421–434, 2024.
- [7] M. Ariska et al., "Effectivity of a hybrid classroom-based reflective microlearning model for prospective physics teachers," *J. Pendidik. MIPA*, vol. 24, no. 3, pp. 710–716, 2023.
- [8] M. Darmastowo, M. Putra, D. Handoko, and M. S. Rosid, "Rainfall estimation in equatorial region using weather radar-based machine learning," in *Proc. 2023 Int. Seminar Appl. Technol. Inf. Commun. (iSemantic)*, 2023, pp. 266–270, IEEE.
- [9] M. Ariska et al., "Pemodelan numerik hubungan pola curah hujan wilayah equatorial di Pulau Sumatera terhadap fenomena ENSO dan IOD," *J. Teori Apl. Fis.*, pp. 95–106, 2023.
- [10] M. Ariska et al., "Trend of rainfall pattern in Palembang for 20 years and link to El-Niño Southern Oscillation (ENSO)," *J. Ilm. Pendidik. Fis. Al-Biruni*, vol. 12, no. 1, pp. 67–75, 2023.
- [11] M. Ariska et al., "Prediksi perubahan iklim ekstrem di kota Palembang dan kaitannya dengan fenomena El Niño-Southern Oscillation (ENSO) berbasis machine learning," *JIPFRI*, vol. 6, no. 2, pp. 79–86, 2022.
- [12] M. Ariska, S. Suhadi, and D. K. Herlambang, "Empirical Orthogonal Function (EOF) analysis based on Google Colab on sea surface temperature (SST) dataset in Indonesian waters," *Indones. Phys. Rev.*, vol. 6, no. 1, pp. 20–32, 2023.
- [13] M. Ariska, H. Akhsan, and M. Muslim, "Impact profile of ENSO and dipole mode on rainfall as anticipation of hydrometeorological disasters in the province of South Sumatra," *Spektra J. Fis. Apl.*, vol. 7, no. 3, pp. 127–140, 2022.
- [14] M. Ariska et al., "Exploration of seasonal dynamics of tropical Indo-Pacific Ocean during dry, wet and neutral years in Indonesia using composite method," *J. Penelit. Fis. Apl. (JPFA)*, vol. 14, no. 1, 2024.
- [15] E. H. Nugrahani et al., "Sensitivity and feature importance of climate factors and evaluation of different machine learning models for predicting fire hotspots in Kalimantan, Indonesia," *Int. J. Artif. Intell.*, vol. 13, no. 2, pp. 2212–2225, 2024.
- [16] J. Derot, "Improved climate time series forecasts by machine learning using signature methods," *Environ. Model. Softw.*, vol. 168, p. 105731, 2024.
- [17] M. I. J. Putra and S. Phinn, "Machine learning and Bayesian method for monitoring and forecasting Jayawijaya's tropical glacier change," in *Proc. ClimateChange.AI @ ICLR*, 2025.
- [18] A. M. Niculae, A. M. Pascu, and A. Stefan, "Assessing the role of machine learning in climate change research: A bibliometric and thematic analysis," *Sustainability*, vol. 16, no. 24, p. 11086, 2024.
- [19] K. Ali, S. Arsyad, and B. Hendrawan, "Mapping and visualization of research on climate change adaptation in Indonesia: Using Scopus data (2000–2023)," *J. Adv. Public Health*, vol. 11, no. 1, pp. 24–33, 2025.
- [20] F. R. Muhammad, S. W. Lubis, and S. Setiawan, "Impacts of the Madden–Julian Oscillation on precipitation extremes in Indonesia," *Atmos. Res.*, vol. 246, p. 105129, 2020.
- [21] P. Lestari and R. Nurrahman, "Application of XGBoost for rainfall intensity prediction in tropical climate regions," *J. Hydrol. Reg. Stud.*, vol. 41, p. 101089, 2022.
- [22] Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5–32.
- [23] R. Saputra and H. Purnomo, "Climate variability and flood hazard mapping in Sumatra using machine learning," *Nat. Hazards*, vol. 108, no. 2, pp. 1281–1298, 2021.
- [24] D. Rahmawati and Y. Nugroho, "Long-term sea level rise prediction using deep learning models in the Indonesian maritime continent," *Ocean Coast. Manag.*, vol. 239, p. 106478, 2023.

- [25] M. Rasyid and M. P. Hadi, "Predicting El Niño-Southern Oscillation impacts on rainfall using machine learning models in Eastern Indonesia," *Theor. Appl. Climatol.*, vol. 142, no. 3, pp. 1273–1285, 2020.
- [26] H. Siregar and R. Nabila, "Evaluation of machine learning models for predicting tropical cyclone occurrences in Indonesian waters," *Meteorol. Appl.*, vol. 29, no. 5, p. e2105, 2022.
- [27] S. Wibowo and Z. Arifin, "Integration of satellite remote sensing and machine learning for drought risk assessment in Kalimantan," *Remote Sens. Appl. Soc. Environ.*, vol. 31, p. 100986, 2024.
- [28] M. Ariska and H. Akhsan, "Spatiotemporal modeling of rainfall anomalies in Sumatera using ensemble machine learning approaches," *Int. J. Climatol.*, vol. 43, no. 12, pp. 5021–5035, 2023.
- [29] R. Pratama and A. Wiratama, "Comparative analysis of ANN and LSTM for predicting extreme rainfall in equatorial Indonesia," *J. Water Clim. Change*, vol. 15, no. 2, pp. 329–339, 2024.