



PERBANDINGAN KINERJA MODEL ARIMA DAN LSTM UNTUK PERAMALAN CURAH HUJAN DI KALIMANTAN TENGAH

KHUSNIA NURUL KHIKMAH^{1*} DAN A'YUNIN SOFRO²

¹Program Studi Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Palangka Raya,
Palangka Raya, Kalimantan Tengah, 74874 Indonesia

²Program Studi Sains Aktuaria, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Surabaya,
Surabaya, Jawa Timur, 60231 Indonesia

*khusniank@gmail.com

ABSTRAK

Curah hujan adalah parameter iklim krusial yang memengaruhi berbagai sektor hingga pada mitigasi bencana hidrometeorologi Provinsi Kalimantan Tengah. Fluktuasi curah hujan yang tidak terprediksi ini berpotensi untuk menimbulkan dampak sosial yang mendorong kebutuhan analisis terkait model peramalan yang akurat. Penelitian mengusulkan perbandingan kinerja pendekatan statistika dasar dengan model *autoregressive integrated moving average* (ARIMA) dan statistika pembelajaran mesin dengan *long short-term memory* (LSTM) untuk meramalkan curah hujan di Kalimantan Tengah. Dimana data yang digunakan diambil dari website resmi Badan Pusat Statistik Kalimantan tengah. Hasil analisis yang dilakukan menunjukkan bahwa model ARIMA memberikan akurasi peramalan yang lebih baik dibandingkan model LSTM yang didasarkan pada nilai RMSE. Dimana nilai RMSE data latih dan data uji sebesar 106.82 dan 115.82. Implikasi hasil penelitian ini adalah rekomendasi penggunaan model ARIMA untuk alat peramalan yang efektif untuk mendukung mitigasi bencana dan peringatan dini.

Kata Kunci: ARIMA, Curah Hujan, Kalimantan Tengah, LSTM, RMSE

ABSTRACT

Rainfall is a crucial climate parameter that affects various sectors, including the hydrometeorological disaster mitigation of Central Kalimantan Province. These unpredictable fluctuations in rainfall have the potential to cause social impacts that encourage the need for analysis related to accurate forecasting models. The research compares the performance of basic statistical approaches with autoregressive integrated moving average (ARIMA) models and machine learning statistics with long short-term memory (LSTM) to forecast rainfall in Central Kalimantan. Where the data used is taken from the official website of the Central Kalimantan Statistics Agency. The analysis results show that the ARIMA model provides better forecasting accuracy than the LSTM model based on the RMSE value. The RMSE values of training and test data are 106.82 and 115.82. The implication of the results of this study is the recommendation to use the ARIMA model for practical forecasting tools to support disaster mitigation and early warning.

Keywords: ARIMA, Rainfall, Central Kalimantan, LSTM, RMSE

1 Pendahuluan

Parameter iklim fundamental yang memengaruhi aspek kehidupan adalah curah hujan. Curah hujan berperan penting dalam aspek kehidupan seperti pangan dalam pertanian, manajemen sumber daya air, hingga pada bencana seperti banjir dan kekeringan [1], [2]. Kelebihan maupun kekurangan curah hujan akan menimbulkan berbagai dampak sosial hingga ekonomi yang signifikan terutama pada wilayah dengan fluktuasi curah hujan yang ekstrem, salah satunya Provinsi Kalimantan Tengah [3]. Secara geografis Provinsi Kalimantan Tengah didominasi hutan tropis dan sistem sungai yang kompleks menjadikan wilayah Kalimantan Tengah rentan terhadap variabilitas curah hujan. Ketersediaan air yang memadai dan pola curah hujan yang stabil menjadi salah satu penentu keberhasilan aktivitas ekonomi di Kalimantan Tengah seperti ada perkebunan kelapa sawit dan pertanian [4], [5]. Oleh karena itu, kemampuan untuk memprediksi curah hujan secara akurat menjadi fundamental bagi pemerintah daerah dan regulator untuk dapat membuat keputusan yang terencana dan terinformasi terhadap langkah-langkah adaptasi yang efektif.

Permasalahan terkait peramalan curah hujan secara umum dapat dianalisis dengan menggunakan model statistik. Penelitian ini menawarkan dua pendekatan statistika dasar dan statistika pembelajaran mesin dalam meramalkan data curah hujan di Kalimantan Tengah ini. Pendekatan statistika dasar dengan model *autoregressive integrated moving average* (ARIMA) [6] dan untuk pendekatan statistika pembelajaran mesin dengan model *long short-term memory* (LSTM) [7]. Model ARIMA yang dipilih dalam penelitian ini memertimbangkan kemampuannya dalam menangkap pola struktur temporal seperti tren dan musin dalam data deret waktu tak stasioner. Selain itu, pertimbangan lainnya dalam analisisnya yang sistematis untuk mengidentifikasi, mengestimasi, hingga diagnostik model untuk memberikan hasil ramalan yang akurat dan *robust* [8].

Penelitian sebelumnya pada [9] menunjukkan bahwa model ARIMA memiliki akurasi yang terbaik dibandingkan *convolutional neural network* (CNN). Model kedua adalah dengan LSTM dimana model ini dipilih berdasarkan kemajuan dalam bidang pembelajaran mesin yang muncul sebagai alternatif dengan kemampuan yang mampu menangkap pola non-linear kompleks sehingga akurasi peramalan yang dihasilkan lebih baik [10]. Model LSTM sendiri dirancang untuk mempelajari data dengan dependensi jangka panjang dan mempertahankan informasi yang relevan. Meskipun pada realitanya model ini *black-box* dalam kinerjanya namun berdasarkan penelitian sebelumnya pada [7] menunjukkan bahwa model LSTM memberikan akurasi yang baik pada masalah kemiskinan dengan tingkat akurasi sebesar $\geq 90\%$.

Secara umum penelitian ini memberikan kebaruan terkait perbandingan komprehensi kinerja model ARIMA sebagai representasi pendekatan statistika dasar dan model LSTM sebagai representasi pendekatan statistika pembelajaran mesin untuk meramalkan curah hujan di Kalimantan Tengah. Kedua model tersebut akan dilakukan evaluasi akurasi terhadap peramalannya berdasarkan ukuran keakuratan *root mean squared error* (RMSE). Hasil penelitian ini diharapkan mampu memberikan pemahaman yang lebih detail terkait keunggulan dan keterbatasan masing-masing model yang diajukan khususnya dalam menganalisis data curah hujan. Rekomendasi model yang terakurat dan efisien yang didapatkan pada penelitian ini diharapkan mampu memberikan pandangan secara matematis untuk menjadi dasar bagi pembuat regulasi untuk dapat mengembangkan sistem peringatan dini hingga penyusunan kebijakan terhadap adaptasi iklim di Kalimantan Tengah yang tujuannya untuk meningkatkan ketahanan dan kesejahteraan masyarakat.

2 Tinjauan Pustaka

2.1 Autoregressive Integrated Moving Average (ARIMA)

Autoregressive integrated moving average (ARIMA) adalah salah satu model deret waktu *univariate* yang mengkombinasikan antara *autoregressive* dengan *moving average* dimana secara umum data yang dimodelkan dengan metode ini adalah data tidak stasioner. Model ini pertama diperkenalkan oleh George E. P. Box. dan Gwilym M. Jenkins sehingga model ini dikenal juga sebagai model Box-Jenkins yang mana secara sistematis berkinerja untuk menganalisis model deret waktu yang menunjukkan pola musiman, tren, dan autokorelasi [11]. Model ARIMA dapat ditulis sebagai $ARIMA(p, d, q)$ dimana p adalah ordo untuk *autoregressive*, q adalah ordo untuk *moving average*, dan d ada nilai pembeda atau *differencing* sehingga data menjadi stasioner. Dengan menggunakan operator *backshift* (B) secara matematis model $ARIMA(p, d, q)$ dapat ditulis sebagai berikut [6].

$$\phi_p(B)(1 - B)^d Y_t = \theta_q(B)\epsilon_t \quad (1)$$

ϕ_p adalah proses *autoregressive* dimana $\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots, \phi_p B^p$. θ_q adalah proses *moving average* dimana $\theta_q(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$ dan ϵ_t adalah sisaan. Penentuan ordo p dan q pada penelitian ini adalah dengan melalui plot *autocorrelation function* (ACF), *partial autocorrelation function* (PACF), dan *extended autocorrelation function* (EACF).

2.2 Long Short-Term Memory (LSTM)

Long short-term memory (LSTM) adalah salah satu metode peramalan pembelajaran mesin yang merupakan perluasan dari *recurrent neural network* (RNN) dimana metode ini mengatasi masalah *vanishing gradient* atau kekurangan terhadap pembaharuan pembobotan model [12]. Secara umum metode LSTM memiliki komponen inti sel memori dan gerbang. Sel memori yang disimbolkan dengan C_t ini berfungsi sebagai jalur yang memungkinkan informasi tersampaikan tanpa mempertimbangkan oleh perubahan di setiap langkah waktu sehingga informasi yang dibawa relevan dalam jangka waktu yang panjang. Untuk komponen gerbang pada LSTM terdiri dari gerbang *input*, gerbang lupa, dan gerbang *output*.

Gerbang *input* yang disimbolkan dengan in_t adalah gerbang masukan yang memutuskan informasi baru yang akan disimpan di sel memori dimana secara matematis nilai in_t didefinisikan sebagai berikut.

$$in_t = \sigma(W_i Y_t + W_i h_{t-1} + b_i) \quad (2)$$

σ adalah fungsi sigmoid, W_i adalah matriks bobot di gerbang input, Y_t adalah data pada *input* waktu ke- t , h_{t-1} adalah *hidden state* waktu ke- $(t - 1)$ dan b_i adalah bias gerbang *input*. Selanjutnya, untuk kandidat nilai baru yang akan ditambahkan ke sel memori disimbolkan dengan $\underline{C}_t$, dimana W_c adalah matriks bobot gerbang masukan dari sel memori, b_c adalah bias dari sel memori. Maka nilai kandidat tersebut secara matematis didefinisikan sebagai berikut [13].

$$\underline{C}_t = \tanh \tanh (W_c Y_t + W_c h_{t-1} + b_c) \quad (3)$$

Gerbang lupa fo_t adalah gerbang yang berfungsi memutus informasi yang diabaikan dari sel memori sebelumnya C_{t-1} . W_f adalah matriks bobot untuk gerbang lupa, Y_t adalah *input* data waktu ke- t , dan b_f adalah bias gerbang lupa [14].

$$fo_t = \sigma(W_f Y_t + W_f h_{t-1} + b_f) \quad (4)$$

Nilai dari sel memori yang telah diperbaharui yang disimbolkan dengan C_t dimana $C_t = in_t * \underline{C}_t + fo_t * C_{t-1}$. Nilai dari C_t ini selanjutnya digunakan pada gerbang keluaran Out_t . Gerbang ini berfungsi memutuskan nilai dari sel memori yang akan menjadi *hidden state* h_t dimana nilai tersebut telah difilter dan melewati fungsi aktivasi $\tanh$, $\tanh(x) = 2\sigma(2x) - 1$ dan fungsi aktivasi sigmoid $\sigma = \frac{1}{1+e^{-x}}$. W_o adalah matriks bobot untuk gerbang keluaran. V_o matriks bobot untuk gerbang keluaran dan b_o bias untuk gerbang keluaran [15].

$$out_t = \sigma(W_o Y_t + W_o h_{t-1} + V_o C_t + b_o) \quad (5)$$

$$h_t = out_t * \tanh \tanh(C_t) \quad (6)$$

2.3 Root Mean Squared Error (RMSE)

Root mean squared error (RMSE) adalah salah satu matrik evaluasi kinerja model yang mana mengukur rata-rata kesalahan prediksi model. Dimana penentuan model terbaiknya didasarkan pada nilai RMSE terkecil. Jika suatu data dengan N jumlah observasi dengan nilai aktual dari observasi ke- t adalah y_t dan nilai prediksi oleh model untuk observasi ke- t adalah $\hat{y}_t$. Maka, nilai RMSE secara matematis dapat didefinisikan sebagai berikut [16].

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_t - \hat{y}_t)^2} \quad (7)$$


2.4 Data dan Langkah Analisis

Data yang digunakan dalam penelitian ini adalah data sekunder, yaitu data curah hujan yang diambil dari website resmi Badan Pusat Statistik (BPS) Kalimantan Tengah dengan data curah dari Januari 2009 hingga Desember 2023. Selanjutnya data ini dilakukan analisis dengan tahapan sebagai berikut.

1. *Preprocessing* data
 - a. Mengumpulkan data.
 - b. Pembersihan data.
 - c. Penanganan data hilang: *linear interpolation*.
 - d. Pengujian kestasioneran data dan transformasi data.
2. Eksplorasi data
 - a. Visualisasi data yang diajukan.
3. Pembagian data: data latih 80% dan data uji 20%.
4. Pemodelan dengan statistika model dasar
 - a. Menggunakan data hasil dari langkah (1).
 - b. Membangun model ARIMA.
5. Pemodelan dengan statistika pembelajaran mesin
 - a. Menggunakan data hasil dari langkah (1).
 - b. Menentukan *hyperparameter* model.
 - c. Membangun model LSTM.
6. Perbandingan hasil analisis: membandingkan akurasi peramalan.
7. Interpretasi.

3 Hasil dan Pembahasan

Data curah hujan yang digunakan dalam analisis penelitian ini dari Januari 2009 hingga Desember 2023 selanjutnya dilakukan praproses dimana untuk penanganan data hilang digunakan metode *linear interpolation*. Hasil imputasi penanganan data hilang ini digunakan untuk analisis, dimana memiliki visualisasi yang ditunjukkan oleh Gambar 1.



Gambar 1. Data Curah Hujan Kalimantan Tengah

Data pada Gambar 1 secara umum memiliki statistik deskriptif data yang disajikan pada Tabel 1. Berdasarkan Tabel 1 rata-rata curah hujan setiap bulan di Kalimantan tengah adalah sebesar 256.834mm dimana secara rata-rata setiap bulan curah hujan di Kalimantan Tengah menyimpang sekitar 140.083mm dari rata-rata keseluruhan.

Tabel 1: Statistik Deskriptif Curah Hujan

Statistik Deskriptif	Nilai (mm)
Rata-rata	256.844
Nilai Tengah	259.650
Standar Deviasi	140.083
Varians	19623.200
Minimum	7.000
Maksimum	729.100

Analisis selanjutnya adalah tahap pemodelan yang dilakukan dengan dua pendekatan statistika dasar dengan ARIMA dan statistika pembelajaran mesin dengan LSTM. Dimana data yang dianalisis dengan kedua kajian ini dilakukan pembagian data terlebih dahulu dengan 80% data digunakan sebagai data latih dan 20% data sisanya digunakan sebagai data uji. Analisis pertama dengan ARIMA dengan melakukan pengujian kestasioneran data dengan uji *Augmented Dickey-Fuller* (ADF). Uji ADF yang dilakukan ini memiliki hipotesis untuk H_0 adalah data tidak stasioner dengan H_1 adalah data sudah stasioner. Penelitian ini menggunakan taraf signifikansi $\alpha = 5\%$ dimana nilai $p - value$ hasil analisis $p - value = 0.01 < 0.05$

sehingga menolak H_0 sehingga data curah hujan sudah stasioner sehingga pemodelan dapat dilakukan.

Kandidat model ARIMA yang diperoleh pada penelitian ini didasarkan pada plot *autocorrelation function* (ACF), *partial autocorrelation function* (PACF), dan *extended autocorrelation function* (EACF), dimana kandidat model ARIMA yang diperoleh disajikan pada Tabel 2.

Tabel 2: Kandidat Model ARIMA

Model	AIC
ARIMA(0,0,2)	1785.28
ARIMA(1,0,0)	1782.26
ARIMA(1,0,1)	1783.92
ARIMA(1,0,2)	1784.61
ARIMA(2,0,2)	1765.18

Kandidat model yang dibandingkan ini digunakan untuk menentukan model terbaik yang didasarkan pada nilai AIC terkecilnya. Sehingga model terbaik yang didapatkan adalah ARIMA(2,0,2). Model terbaik yang didapatkan ini selanjutnya dilakukan pendugaan parameter dan diagnostik model dengan uji formalitas yang tersaji secara lengkap pada Tabel 3. Uji formalitas yang dilakukan pada penelitian ini masing-masing menggunakan taraf signifikansi $\alpha = 5\%$. Uji formalitas yang dilakukan adalah uji normalitas dengan Kolmogorov-Smirnov, uji nilai tengah sisaan dengan uji t, dan uji autokorelasi dengan Ljung-Box.

Tabel 3: Pendugaan Parameter dan Diagnostik Model

Pendugaan Parameter		Diagnostik Model					
Nilai dugaan	p-value	Uji Normalitas		Uji Nilai Tengah Sisaan		Uji Autokorelasi	
		p-value	Keputusan	p-value	Keputusan	p-value	Keputusan
$\phi_1 = 1.6843$	2.22×10^{-16}	2.22×10^{-16}	Tolak H_0 atau sisaan tidak menyebar normal	0.92676	Tolak H_0 atau nilai tengah sisaan tidak sama dengan nol	0.76142	Gagal menolak H_0 atau tidak terdapat gejala autokorelasi
$\phi_2 = -0.9297$	2.22×10^{-16}						
$\theta_1 = 1.4212$	2.22×10^{-16}						
$\theta_2 = -0.7144$	1.28×10^{-8}						

Berdasarkan Tabel 3 nilai dugaan yang telah dilakukan memenuhi asumsi nilai tengah sisaannya sama dengan nol dan tidak terdapat gejala autokorelasi. Sehingga, model ini layak digunakan untuk peramalan. Secara matematis model terbaik yang diperoleh dengan menggunakan penjabaran operator *backshift* model ARIMA(2,0,2) memiliki persamaan sebagai berikut.

$$\phi_p(1-B)^d Y_t = \mu + \theta_q(B)e_t$$

$$(1 - \phi_2(B))(1-B)^0 Y_t = \mu + \theta_2(B)e_t$$

$$Y_t = \mu + 1.6843Y_{t-1} - 0.9297Y_{t-2} - 1.4212e_{t-1} - 0.7144e_{t-2} + e_t$$

Analisis kedua adalah dengan menggunakan pendekatan statistika pembelajaran mesin dengan LSTM. Secara umum model LSTM tidak memiliki aturan baku dalam penentuan *hyperparameter* sehingga nilai ini dipilih dengan inisialisasi berdasarkan penelitian sebelumnya. *Hyperparameter* yang diajukan dalam penelitian ini adalah nilai *epoch*, *batch size*, dan *neuron*. Inisialisasi *hyperparameter* dimana *layer* LSTM yang digunakan adalah satu dengan *neuron* 2500, *epoch* sebanyak 3000, dan *batch size* nya 1500. Secara lengkap inisialisasi ini tersaji pada Tabel 4.

Tabel 4: Inisialisasi *hyperparameter* LSTM

Parameter	Nilai Spesifikasi
Unit <i>neuron</i>	25
LSTM <i>layer</i>	1 LSTM <i>layer</i>
Jumlah dense <i>layer</i>	1 dense <i>layer</i>
Fungsi aktivasi	tanh
Optimizer	Adam
<i>Batch size</i>	15
<i>epoch</i>	30

Nilai ini selanjutnya diterapkan pada data latih untuk dilakukan pemodelan pada data awal yang telah dilakukan normalisasi. Selanjutnya model baik dari ARIMA maupun LSTM dengan data latih ini dilakukan validasi dengan dimodelkan dan meramalkan data uji dimana matriks evaluasi yang digunakan adalah RMSE. Nilai RMSE ramalan kedua model tersebut tersaji pada Tabel 5 berikut.

Tabel 5: RMSE Peramalan Data Uji

Model	RMSE	
	Data Latih	Data Uji
ARIMA	106.82	115.82
LSTM	115.94	143.46

Berdasarkan nilai RMSE hasil ramalan baik data latih maupun data uji curah hujan dengan model ARIMA dan LSTM diperoleh bahwa RMSE ramalan model ARIMA lebih kecil dibandingkan model LSTM. Temuan pada penelitian ini sesuai pada penelitian sebelumnya pada [17] yang menemukan bahwa model statistika dasar akan bagus digunakan ketika data yang digunakan dalam analisis adalah data dengan jumlah terbatas atau bukan data besar (*big data*). Dimana hasil penelitian ini menunjukkan model ARIMA 1.8 dan 2.1 kali lebih baik dibandingkan LSTM untuk peramalan kasus bursa saham. Selain itu, secara umum bahwa data yang digunakan merupakan data stasioner sehingga efektivitas model ARIMA relative efektif dan mampu menangkap pola data dengan lebih baik dibandingkan LSTM yang robust terhadap kompleksitas data.

Analisis yang telah dilakukan pada penelitian ini memiliki kekuatan penelitian yang bertujuan memberikan wawasan penting terhadap kondisi curah hujan di Kalimantan Tengah sehingga intervensi, mitigasi, dan kewaspadaan akibat curah hujan ini menjadi meningkat. Selain itu, penelitian ini juga jauh menyoroti berdasarkan sudut pandang pendekatan statistika dalam menangani masalah curah hujan. Hasil analisis ini juga memberikan pengalaman terkait perbandingan kinerja model peramalan dalam statistika. Konsistensi RMSE model ARIMA

baik pada data latih maupun pada data Uji menunjukkan bahwa model ARIMA lebih cocok digunakan untuk meramalkan curah hujan di Kalimantan Tengah.

4 Kesimpulan

Ramalan terkait masalah curah hujan di Kalimantan Tengah yang secara komprehensif dimodelkan dengan ARIMA dan LSTM kemudian dilakukan perbandingan menunjukkan bahwa model ARIMA memiliki akurasi ramalan RMSE yang lebih baik dibandingkan LSTM. Meskipun model LSTM unggul dalam menangani masalah non-linearitas, namun data curah hujan di Kalimantan Tengah merupakan data stasioner berdasarkan uji ADF sehingga menunjukkan pola linear dan dependensi jangka pendek yang lebih dominan sehingga berhasil ditangkap lebih baik oleh model ARIMA. Oleh karena itu, permasalahan ini merekomendasikan model ARIMA sebagai alat yang lebih efektif dan handa untuk meramalkan curah hujan di Kalimantan Tengah.

Daftar Pustaka

- [1] L. M. Harahap, Y. I. B. Manurung, J. B. Situngkir, and N. A. Simanungkalit, "Pengelolaan Risiko Iklim Dalam Sektor Pertanian: Strategi Dan Implementasi," *Jurnal Ilmu Manajemen, Bisnis dan Ekonomi (JIMBE)*, vol. 1, no. 6, pp. 117–126, 2024.
- [2] L. Budiman and D. Suhendi, "Resiliensi Penguatan Ketahanan Pangan Daerah di Indonesia," *Jurnal Perlindungan Masyarakat: Bestuur Praesidium*, vol. 1, no. 2, pp. 63–71, 2024.
- [3] K. Kamaliah and S. Marlina, "Kajian Dampak dan Adaptasi Perubahan Iklim di Kalimantan Tengah," *Media Ilmiah Teknik Lingkungan (MITL)*, vol. 6, no. 1, pp. 34–42, 2021.
- [4] B. Asmara and T. O. Randhir, "Modeling the impacts of oil palm plantations on water quantity and quality in the Kais River Watershed of Indonesia," *Science of The Total Environment*, vol. 928, p. 172456, 2024.
- [5] T. D. Toumbourou and W. H. Dressler, "Sustaining livelihoods in a palm oil enclave: differentiated gendered responses in East Kalimantan, Indonesia," *Asia Pac Viewp*, vol. 62, no. 1, pp. 40–55, 2021.
- [6] K. N. Khikmah, "COMPARISON OF ARIMA AND GARMA'S PERFORMANCE ON DATA ON POSITIVE COVID-19 CASES IN INDONESIA," *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 16, no. 3, pp. 919–926, 2022.
- [7] K. N. Khikmah, K. Sadik, and K. A. Notodiputro, "Simulation and Empirical Studies of Long Short-Term Memory Performance to Deal with Limited Data," *Jurnal Online Informatika*, vol. 10, no. 1, pp. 216–226, 2025.
- [8] V. Arumugam and V. Natarajan, "Time Series Modeling and Forecasting Using Autoregressive Integrated Moving Average and Seasonal Autoregressive Integrated Moving Average Models.," *Instrumentation, Mesures, Métrologies*, vol. 22, no. 4, 2023.
- [9] M. Nkongolo, "Using ARIMA to predict the growth in the subscriber data usage," *Eng*, vol. 4, no. 1, pp. 92–120, 2023.
- [10] H. Alizadegan, B. Rashidi Malki, A. Radmehr, H. Karimi, and M. A. Ilani, "Comparative study of long short-term memory (LSTM), bidirectional LSTM, and traditional machine learning approaches for energy consumption prediction," *Energy Exploration & Exploitation*, vol. 43, no. 1, pp. 281–301, 2025.
- [11] B. P. Devkota and S. Pokhrel, "Forecasting Remittance Inflow in Nepal Using the Box-Jenkins ARIMA Model," *Kathford Journal of Engineering and Management*, vol. 3, no. 1, pp. 72–86, 2023.

- [12] H. Wan, S. Guo, K. Yin, X. Liang, and Y. Lin, "CTS-LSTM: LSTM-based neural networks for correlated time series prediction," *Knowl Based Syst*, vol. 191, p. 105239, 2020.
- [13] L. Huang, T. Cai, Y. Zhu, Y. Zhu, W. Wang, and K. Sun, "LSTM-based forecasting for urban construction waste generation," *Sustainability*, vol. 12, no. 20, p. 8555, 2020.
- [14] S. Siامي-Namini, N. Tavakoli, and A. S. Namin, "A comparison of ARIMA and LSTM in forecasting time series," in *2018 17th IEEE international conference on machine learning and applications (ICMLA)*, IEEE, 2018, pp. 1394–1401.
- [15] R. Zhang *et al.*, "Comparison of ARIMA and LSTM in forecasting the incidence of HFMD combined and uncombined with exogenous meteorological variables in Ningbo, China," *Int J Environ Res Public Health*, vol. 18, no. 11, p. 6174, 2021.
- [16] T. O. Hodson, "Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not," *Geoscientific Model Development Discussions*, vol. 2022, pp. 1–10, 2022.
- [17] D. Kobiela, D. Krefta, W. Król, and P. Weichbroth, "ARIMA vs LSTM on NASDAQ stock exchange data," *Procedia Comput Sci*, vol. 207, pp. 3836–3845, 2022.