

Perbandingan Akurasi Prediksi Penjualan Energi Listrik Rumah Tangga di Kota Medan Menggunakan Metode SARIMA dan LSTM

Juliana^{1*}, Ismail Husein²

^{1,2} Program Studi Matematika, Universitas Islam Negeri Sumatera Utara, Medan, Indonesia

ABSTRAK

Penelitian ini bertujuan mengevaluasi dan membandingkan kemampuan Seasonal Autoregressive Integrated Moving Average (SARIMA) dan Long Short-Term Memory (LSTM) dalam melakukan peramalan penjualan energi listrik rumah tangga di Kota Medan. Data yang dianalisis berupa data bulanan Januari 2012 sampai Desember 2025 dengan total 168 observasi. Prosedur penelitian mencakup pra-pemrosesan data, pengisian nilai yang tidak tersedia melalui interpolasi linier, pengujian kestasioneran, pembentukan model SARIMA dan LSTM, serta pengukuran akurasi menggunakan Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Hasil analisis menetapkan SARIMA (0,1,2)(1,1,1)₁₂ sebagai model SARIMA terpilih dengan AIC sebesar 2.332,24. Nilai evaluasi SARIMA adalah RMSE 11.094,01, MAE 8.703,92, dan MAPE 10,47%, sedangkan LSTM menghasilkan RMSE 4.392,05, MAE 3.391,29, dan MAPE 3,91%. Karena menghasilkan kesalahan prediksi yang lebih kecil, LSTM ditetapkan sebagai model dengan kinerja terbaik dan digunakan untuk meramalkan penjualan selama 12 bulan pada tahun 2026.

ABSTRACT

This research evaluates and compares the forecasting capability of the Seasonal Autoregressive Integrated Moving Average (SARIMA) and Long Short-Term Memory (LSTM) methods for residential electricity sales in Medan. The dataset consists of monthly observations covering January 2012 through December 2025, totaling 168 observations. The analysis involved data preprocessing, linear interpolation for missing observations, stationarity testing, construction of SARIMA and LSTM models, and accuracy assessment using Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE). The selected SARIMA model was SARIMA (0,1,2)(1,1,1)₁₂ with an AIC value of 2,332.24. SARIMA obtained an RMSE of 11,094.01, an MAE of 8,703.92, and a MAPE of 10.47%, whereas LSTM achieved an RMSE of 4,392.05, an MAE of 3,391.29, and a MAPE of 3.91%. Since LSTM produced lower forecasting errors across the evaluation measures, it was selected for the 12-month forecast for 2026.

Kata Kunci: penjualan energi listrik rumah tangga; SARIMA; LSTM; prediksi; deret waktu

Email: * juli88485@gmail.com

DOI: <http://dx.doi.org/10.30829/jistech.v11i2.31483>



This work is licensed under a [Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-nc-sa/4.0/).

1. Pendahuluan

Energi listrik menjadi salah satu kebutuhan pokok yang menunjang berbagai kegiatan masyarakat, mulai dari aktivitas rumah tangga hingga kegiatan industri, perdagangan, dan pelayanan publik. Perubahan jumlah penduduk, kemajuan teknologi, serta dinamika kegiatan ekonomi dapat memengaruhi kebutuhan listrik dari satu periode ke periode berikutnya. Dalam lingkup rumah tangga, listrik dimanfaatkan untuk penerangan, penggunaan perangkat elektronik, komunikasi, dan berbagai keperluan domestik lainnya. Oleh sebab itu, gambaran mengenai kebutuhan listrik pada periode mendatang diperlukan sebagai bahan pendukung dalam perencanaan penyediaan energi.

Data penjualan energi listrik rumah tangga termasuk dalam kelompok data deret waktu karena setiap pengamatan tersusun berdasarkan periode tertentu. Data tersebut dapat memperlihatkan perubahan nilai, tren, fluktuasi, maupun pola yang berulang secara musiman. Adanya karakteristik tersebut membuat teknik peramalan dapat digunakan dengan memanfaatkan pola historis untuk memperoleh estimasi nilai pada periode berikutnya. Informasi hasil peramalan dapat membantu memberikan gambaran mengenai perkembangan penjualan energi listrik di masa mendatang.

Salah satu pendekatan yang dapat diterapkan pada deret waktu dengan komponen musiman adalah Seasonal Autoregressive Integrated Moving Average (SARIMA). Model ini dapat merepresentasikan hubungan linier sekaligus pola musiman dalam data [4]–[6]. Meskipun demikian, SARIMA mempunyai keterbatasan ketika pola yang terbentuk bersifat nonlinier dan kompleks. Untuk mengatasi karakteristik tersebut, pendekatan deep learning seperti Long Short-Term Memory (LSTM) dapat digunakan. LSTM merupakan pengembangan Recurrent Neural Network (RNN) yang mempunyai mekanisme penyimpanan informasi untuk mempelajari ketergantungan data dalam jangka panjang.

SARIMA dan LSTM memiliki kemampuan yang berbeda dalam menangani data deret waktu. SARIMA lebih sesuai ketika pola musiman dan hubungan linier dalam data dapat diidentifikasi dengan relatif jelas, sedangkan LSTM dirancang untuk mempelajari hubungan nonlinier serta ketergantungan jangka panjang. Sejumlah penelitian telah membandingkan SARIMA dan LSTM pada objek peramalan lain [9], [12], tetapi kajian pada data penjualan energi listrik rumah tangga di Kota Medan masih terbatas. Atas dasar kondisi tersebut, penelitian ini menguji dan membandingkan kedua metode menggunakan data bulanan periode Januari 2012 hingga Desember 2025.

Penelitian ini memiliki tiga sasaran utama, yaitu: (1) membangun model SARIMA dan LSTM untuk meramalkan penjualan energi listrik rumah tangga di Kota Medan; (2) menilai serta membandingkan kinerja kedua model berdasarkan RMSE, MAE, dan MAPE; dan (3) menggunakan model dengan tingkat kesalahan paling rendah untuk menghasilkan ramalan selama 12 bulan berikutnya.

2. Metodologi Penelitian

2.1 Desain Penelitian

Penelitian menggunakan pendekatan kuantitatif dengan fokus pada analisis deret waktu. Objek yang dianalisis adalah data penjualan listrik bulanan pada sektor rumah tangga di Kota Medan selama Januari 2012 sampai Desember 2025. Dua pendekatan peramalan yang diterapkan dalam penelitian ini adalah SARIMA dan LSTM.

2.2 Data dan Pra-pemrosesan

Data penelitian berupa data sekunder bulanan penjualan listrik rumah tangga di Kota Medan yang bersumber dari publikasi Badan Pusat Statistik (BPS) Kota Medan. Periode pengamatan Januari 2012–Desember 2025 menghasilkan 168 titik pengamatan. Pada tahap pemeriksaan kualitas data ditemukan 27 observasi yang tidak tersedia atau missing, setara dengan 16,07% dari keseluruhan data. Untuk membentuk rangkaian bulanan yang lengkap sebelum pemodelan, nilai yang hilang diestimasi menggunakan interpolasi linier. Metode tersebut dipilih karena pengamatan tersusun berurutan setiap bulan sehingga nilai di antara dua pengamatan yang tersedia dapat diperkirakan berdasarkan hubungan linier. Namun, penelitian ini belum membandingkan beberapa alternatif metode imputasi. Dengan demikian, interpolasi linier diperlakukan sebagai bagian dari pra-pemrosesan dan kemungkinan pengaruhnya terhadap hasil peramalan menjadi salah satu keterbatasan penelitian.

Data dibagi secara kronologis menjadi 144 observasi pelatihan untuk periode Januari 2012 hingga Desember 2023 dan 24 observasi pengujian untuk periode Januari 2024 hingga Desember 2025. Pembagian kronologis digunakan agar kedua model dievaluasi pada periode yang lebih baru daripada data pelatihan.

2.3 Model SARIMA


SARIMA digunakan untuk menangani data deret waktu yang memiliki pola tertentu, khususnya ketika terdapat komponen musiman. Model ini merupakan perluasan dari Autoregressive Integrated Moving Average (ARIMA) yang menambahkan komponen musiman [4]–[6]. Bentuk umum model SARIMA dapat dituliskan menggunakan parameter berikut:

$$\text{SARIMA}(p,d,q)(P,D,Q)s \quad (1)$$

Pada notasi tersebut, (p,d,q) menunjukkan orde bagian non-musiman, sedangkan (P,D,Q) menunjukkan orde komponen musiman. Simbol s menyatakan panjang periode yang membentuk satu siklus musiman.

2.4 LSTM

Long Short-Term Memory (LSTM) merupakan arsitektur yang dikembangkan dari Recurrent Neural Network (RNN) untuk memproses data berurutan dan mengurangi kendala vanishing gradient. LSTM memiliki memory cell yang memungkinkan informasi penting dipertahankan dalam rentang waktu yang lebih panjang. Dengan mekanisme tersebut, hubungan antara pengamatan pada periode sebelumnya dapat dipelajari secara lebih efektif. Kemampuan mempertahankan informasi ini membuat LSTM banyak diterapkan pada persoalan peramalan deret waktu, termasuk konsumsi energi, beban listrik, harga saham, kondisi cuaca, dan penjualan [1]–[3], [7], [8], [10], [11].



Gambar 1. Struktur dasar model memory cell LSTM

Struktur sel memori LSTM mencakup keadaan sel (C_t), keadaan tersembunyi (h_t), serta tiga mekanisme gerbang, yaitu forget gate, input gate, dan output gate. Ketiga gerbang tersebut mengendalikan aliran informasi pada setiap langkah waktu sehingga jaringan dapat menentukan informasi yang perlu dihapus, disimpan, dan dikeluarkan.

Operasi pada sel memori dapat dijelaskan secara matematis melalui ketiga gerbang tersebut. Setiap gerbang berperan mengatur informasi yang masuk dan keluar dari sel. Mekanisme ini memungkinkan LSTM mempertahankan informasi yang relevan sekaligus mengurangi pengaruh informasi yang tidak lagi diperlukan. Persamaan untuk setiap tahap dituliskan sebagai berikut.

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

Pada Persamaan (2), f_t menyatakan forget gate, σ merupakan fungsi aktivasi sigmoid, w^f adalah bobot forget gate, h_{t-1} merupakan keadaan tersembunyi pada langkah waktu sebelumnya, x_t adalah nilai masukan, dan b^f merupakan bias forget gate.

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

Persamaan (3) menentukan input gate i_t dengan melibatkan masukan x_t , bobot w^i , bias b^i , dan keadaan tersembunyi h_{t-1} dari langkah waktu sebelumnya.

$$\tilde{C}_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

Selain menentukan input gate, tahap berikutnya menghasilkan kandidat keadaan sel baru $\tilde{C}_t$. Kandidat tersebut dihitung menggunakan fungsi aktivasi tanh sebagai informasi baru yang dipertimbangkan untuk disimpan dalam keadaan sel.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (5)$$

Setelah forget gate, input gate, dan kandidat keadaan sel diperoleh, keadaan sel C_t dihitung dengan menggabungkan informasi lama yang dipertahankan oleh forget gate dan informasi baru yang diteruskan melalui input gate.

$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$


Persamaan (6) menghitung output gate o_t menggunakan fungsi aktivasi sigmoid. Nilai output gate selanjutnya digunakan bersama keadaan sel untuk menentukan keadaan tersembunyi pada langkah waktu berjalan.

$$h_t = o_t * \tanh(C_t) \quad (7)$$


Output gate menentukan bagian informasi yang dikeluarkan sebagai keadaan tersembunyi h_t . Proses tersebut menerapkan fungsi tanh pada keadaan sel C_t , kemudian menggabungkan hasilnya dengan output gate o_t .

3. Hasil dan Pembahasan

Data yang digunakan berjumlah 168 observasi bulanan selama Januari 2012 hingga Desember 2025. Pola data menunjukkan perubahan nilai antarbulan secara berkala. Pada sekitar 2012–2018 terlihat kecenderungan meningkat, kemudian terjadi penurunan yang cukup kuat pada 2019–2020. Setelah periode tersebut, penjualan kembali mengalami peningkatan dengan fluktuasi hingga akhir masa pengamatan.



Gambar 2. Grafik penjualan energi listrik rumah tangga Januari 2012–Desember 2025



Gambar 3. Dekomposisi data penjualan energi listrik rumah tangga

3.1 Pemodelan SARIMA

a. Uji Stasioneritas

Kestasioneran merupakan salah satu kondisi penting sebelum model SARIMA dibentuk. Suatu deret waktu dikatakan stasioner apabila karakteristik statistik utamanya, terutama rata-rata dan varians, relatif tidak berubah sepanjang waktu. Oleh karena itu, pengujian Augmented Dickey-Fuller (ADF) dilakukan terlebih dahulu untuk mengetahui apakah deret data telah memenuhi kondisi tersebut.

H_0 : Data mengandung akar unit sehingga tidak stasioner.

H_1 : Data tidak mengandung akar unit sehingga stasioner.


```
ADF data asli : stat= -1.4415 p-value=0.5622 -> TIDAK STASIONER
Perbedaan ADF 1 : stat= -5.9725 p-value=0.0000 -> STASIONER
Perbedaan ADF non-musiman : stat= -5.9725 p-value=0.0000 -> STASIONER
Perbedaan ADF musiman (lag 12) : stat= -4.8437 p-value=0.0000 -> STASIONER
```

Gambar 4. Hasil uji ADF setelah differencing

Hasil pengujian menunjukkan bahwa deret awal belum stasioner. Nilai statistik ADF sebesar $-1,4415$ dengan p -value $0,5622$ menyebabkan hipotesis nol mengenai keberadaan unit root tidak dapat ditolak. Setelah diterapkan differencing non-musiman orde pertama dan differencing musiman dengan periode 12, statistik ADF masing-masing menjadi $-5,9725$ dan $-4,8437$ dengan p -value $0,0000$. Hasil tersebut menunjukkan bahwa deret setelah proses differencing telah memenuhi kondisi stasioner.

b. Analisis Fungsi Autokorelasi (ACF) dan Fungsi Autokorelasi Parsial (PACF)

Setelah kestasioneran tercapai melalui differencing, tahap berikutnya adalah menentukan kandidat orde model SARIMA. Proses identifikasi dilakukan dengan mengamati plot Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF) dari data yang telah didifferencing. Kedua plot tersebut digunakan sebagai dasar untuk menyusun beberapa alternatif model yang selanjutnya dibandingkan menggunakan nilai AIC.



Gambar 5. Plot ACF dan PACF setelah differencing

Pada Gambar 5 terlihat lonjakan pada lag 1 dan lag 12 yang melewati batas interval kepercayaan. Kondisi tersebut menunjukkan adanya ketergantungan antarobservasi pada komponen non-musiman maupun musiman. Informasi dari ACF dan PACF kemudian digunakan untuk menyusun kandidat model SARIMA. Kandidat-kandidat tersebut dibandingkan berdasarkan nilai AIC, dengan model yang mempunyai nilai AIC paling kecil diprioritaskan sebagai model terpilih.

c. Model SARIMA Terbaik

Estimasi model kandidat dilakukan melalui grid search dengan mempertimbangkan orde non-musiman dan musiman yang telah diidentifikasi. Kriteria utama dalam pemilihan model adalah Akaike Information Criterion (AIC), karena nilai yang lebih kecil menunjukkan kompromi yang lebih baik antara kesesuaian model dan kompleksitasnya. Bayesian Information Criterion (BIC) juga digunakan sebagai pertimbangan tambahan dengan prinsip pemilihan nilai yang lebih rendah. Sementara itu, log-likelihood ditafsirkan secara berlawanan, yaitu nilai yang lebih besar menunjukkan kecocokan model yang lebih baik apabila kondisi lainnya dianggap sama. Model terpilih selanjutnya diperiksa melalui diagnosis residu.

SARIMAX Results

Dep. Variable:

Penjualan

No. Observations:

144

Model:

SARIMAX(0, 1, 2)x(1, 1, [1], 12)

Log Likelihood

-1161.121

Date:

Wed, 22 Jul 2026

AIC

2332.242

Time:

02:15:46

BIC

2346.010

Sample:

01-01-2012

HQIC

2337.831

- 12-01-2023

Covariance Type:

opg

coef

std err

z

P>|z|

[0.025

0.975]

ma.l1

-0.3198

0.069

-4.603

0.000

-0.456

-0.184

ma.l2

0.2089

0.078

2.664

0.008

0.055

0.363

ar.S.l12

-0.3183

0.123

-2.586

0.010

-0.559

-0.077

ma.S.l12

-0.3584

0.066

-5.465

0.000

-0.487

-0.230

sigma2

2.88e+07

3.51e-10

8.19e+16

0.000

2.88e+07

2.88e+07

Ljung-Box (L1) (Q):

0.20

Jarque-Bera (JB):

22.64

Prob(Q):

0.65

Prob(JB):

0.00

Heteroskedasticity (H):

0.76

Skew:

-0.10

Prob(H) (two-sided):

0.39

Kurtosis:

5.15

Warnings:

[1] Covariance matrix calculated using the outer product of gradients (complex-step).

[2] Covariance matrix is singular or near-singular, with condition number 7.59e+32. Standard errors may be unstable.


Gambar 6. Hasil Estimasi Parameter Model SARIMA

Parameter model terpilih memberikan estimasi MA(1) sebesar $-0,3198$, MA(2) sebesar $0,2089$, SAR(1) sebesar $-0,3183$, dan SMA(1) sebesar $-0,3584$. Kombinasi parameter tersebut sesuai dengan spesifikasi SARIMA $(0,1,2)(1,1,1)_{12}$.

d. Diagnosis Residu

Secara visual, histogram residu terkonsentrasi di sekitar nilai nol dan menunjukkan bentuk yang mendekati distribusi normal. Residu terstandarisasi tidak memperlihatkan pola sistematis yang menonjol, sedangkan korelogram menunjukkan korelasi yang masih berada dalam interval kepercayaan 95%. Hasil uji Ljung-Box memberikan Prob(Q) sebesar $0,65$ ($> 0,05$), sehingga tidak ditemukan autokorelasi residual yang signifikan. Namun, uji Jarque-Bera menghasilkan Prob(JB) sebesar $0,00$ sehingga asumsi normalitas residual belum terpenuhi. Dengan demikian, model dapat dinilai memadai dari sisi independensi residual, tetapi

ketidaknormalan residual tetap perlu dicatat sebagai keterbatasan.



Gambar 7. Diagnosis Residu Model SARIMA

Model kemudian dievaluasi menggunakan data pengujian.

Tabel 1. Hasil Evaluasi Model SARIMA

Model	RMSE	MAE	MAPE
SARIMA	11.094,01	8.703,92	10,47%

3.2. Pemodelan LSTM

Pengembangan model LSTM dilakukan setelah data dipersiapkan melalui differencing, normalisasi menggunakan MinMaxScaler, penyusunan urutan input, dan pelatihan jaringan. Konfigurasi terbaik yang dilaporkan menggunakan satu lapisan LSTM dengan 64 unit, dropout sebesar 20% untuk mengurangi risiko overfitting, serta satu lapisan Dense sebagai lapisan keluaran untuk menghasilkan nilai prediksi.

Pada data pengujian, model LSTM menghasilkan RMSE sebesar 4.392,05, MAE sebesar 3.391,29, dan MAPE sebesar 3,91%. MAPE yang relatif rendah menunjukkan bahwa rata-rata kesalahan relatif model pada data pengujian relatif kecil.

Tabel 2. Hasil Evaluasi Model LSTM


Model	RMSE	MAE	MAPE
LSTM	4.392,05	3.391,29	3,91%

3.3. Perbandingan Kinerja SARIMA dan LSTM

Evaluasi kedua metode dilakukan pada data pengujian yang sama menggunakan tiga ukuran kesalahan, yaitu RMSE, MAE, dan MAPE. Ketiga ukuran menunjukkan bahwa LSTM menghasilkan kesalahan yang lebih rendah daripada SARIMA. RMSE LSTM sebesar 4.392,05, sedangkan SARIMA mencapai 11.094,01. Untuk MAE, LSTM memperoleh 3.391,29 dan SARIMA 8.703,92. Sementara itu, MAPE LSTM sebesar 3,91%, lebih rendah daripada SARIMA yang mencapai 10,47%. Secara relatif, LSTM menurunkan RMSE, MAE, dan MAPE masing-masing sekitar 60,41%, 61,04%, dan 62,66% dibandingkan SARIMA. Berdasarkan seluruh ukuran tersebut, LSTM ditetapkan sebagai model dengan kinerja prediksi terbaik pada konfigurasi dan pembagian data yang digunakan.

Tabel 3. Perbandingan Kinerja Model SARIMA dan LSTM


Model	RMSE	MAE	MAPE
SARIMA	11.094,01	8.703,92	10,47%
LSTM	4.392,05	3.391,29	3,91%



Gambar 8. Perbandingan hasil prediksi model SARIMA dan LSTM

3.4. Peramalan Penjualan Energi Listrik Tahun 2026

Model dengan kinerja terbaik selanjutnya digunakan untuk menghasilkan peramalan selama 12 bulan, mulai Januari hingga Desember 2026. Hasil peramalan menunjukkan bahwa prediksi SARIMA berada dalam rentang 91.616,72–99.179,52, sedangkan prediksi LSTM berada dalam rentang 73.480,57–75.774,18. Karena LSTM menghasilkan nilai kesalahan yang lebih kecil pada seluruh ukuran evaluasi, hasil prediksi LSTM digunakan sebagai acuan utama untuk periode 2026.



Gambar 9. Peramalan penjualan energi listrik rumah tangga tahun 2026

4. Kesimpulan

Penelitian ini membandingkan SARIMA dan LSTM dalam meramalkan penjualan energi listrik rumah tangga di Kota Medan berdasarkan 168 data bulanan dari Januari 2012 hingga Desember 2025. Sebanyak 27 nilai hilang ditangani melalui interpolasi linier pada tahap pra-pemrosesan. Model SARIMA terbaik adalah SARIMA (0,1,2)(1,1,1)₁₂ dengan AIC 2.332,24. Pada data pengujian, SARIMA menghasilkan RMSE 11.094,01, MAE 8.703,92, dan MAPE 10,47%, sedangkan LSTM menghasilkan RMSE 4.392,05, MAE 3.391,29, dan MAPE 3,91%. Karena seluruh ukuran kesalahan LSTM lebih rendah, metode tersebut dipilih sebagai model dengan kinerja terbaik. Untuk peramalan tahun 2026, rentang prediksi SARIMA adalah 91.616,72–99.179,52 dan rentang prediksi LSTM adalah 73.480,57–75.774,18. Temuan ini dapat digunakan sebagai informasi pendukung untuk memperkirakan penjualan energi listrik rumah tangga di Kota Medan.

Ucapan Terima Kasih

Penulis menyampaikan apresiasi kepada Universitas Islam Negeri Sumatera Utara serta seluruh pihak yang telah memberikan dukungan dan arahan selama proses penyelesaian penelitian ini.

Daftar Pustaka

- [1] S. Hidayatullah and A. Cherid, "Prediksi Temperatur Cuaca di Negara Norwegia Menggunakan Metode LSTM," SIMKOM, vol. 8, no. 2, hlm. 187–198, Agustus 2023, doi: 10.51717/simkom.v8i2.192.
- [2] F. C. Yulianto and Noor Latifah, "Peramalan Penjualan Laptop Menggunakan Metode Long Short Term Memory (LSTM)," jil. 14, no. 2, 2024, doi: 10.37859/jf.v14i2.7337.
- [3] Endritha Pramudya, D. Retnoningsih, and Diyah Ruswanti, "Implementasi Metode LSTM untuk Prediksi Harga Saham PT Indofood CBP Sukses Makmur TBK," vol. 3, no. 4, 2025.
- [4] L. Fernandes Tokan and A. Hermawan, "Implementasi Model SARIMA Untuk Memprediksi Produksi Minyak Kelapa Sawit," vol. 13, no. 3, hlm. 456–463, Desember 2023.
- [5] N. Irianta Denashurya, "Pengembangan Model SARIMA Untuk Meramalkan Produksi Tanaman Obat di Indonesia," vol. 13, no. 2, hlm. 146–152, 2024.
- [6] H. N. Dewi Fortuna and A. Oktaviarina, "Metode SARIMA Arch Peramalan Jumlah Produksi Padi Kabupaten Ngawi Menggunakan Metode SARIMA Arch," vol. 12, no. 2, 2024.
- [7] R. A. Sembiring and Yoshida Sary, "Analisa Dan Implementasi Long Short-Term Memory (LSTM) Dalam Kebutuhan Persediaan Barang di PT. Gunung Sari Indonesia," vol. 5, no. 3, November 2025.

- [8] Jumina Cahyani and S. Mujahidin, "Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional," vol. 11, no. 2, 2023.
- [9] Nurul Jannah Salsabila and Windu Gata, "Eksistensi Metode ARIMA, SARIMA dan LSTM dalam Memprediksi Penjualan," vol. 13, no. 4, Oktober 2025.
- [10] Humasak Tommy Argo Simanjuntak, Amelia Lumbanraja, Gabriel Samosir, and Regita, "Prediksi Single-Step dan Multi-Step Data Cuaca Menggunakan Model Long Short-Term Memory dan Sarima," vol. 12, no. 2, hlm. 399-410, April 2025.
- [11] M Triyoga Rasyadan, Amalia Rizqi Utami, and Barokatun Hasanah, "Penerapan Metode LSTM, ARIMA dan SARIMA untuk Memprediksi Jam Sibuk Pada Trafik Internet," vol. 16, no. 1, hlm. 13-31, April 2026.
- [12] Desvita Hendri, Inggih Permana, Febi Nur Salisah, M Afdal, Megawati, and Eki Saputra, "Perbandingan Performa Algoritma SVR, LSTM, dan SARIMA dalam Peramalan Produksi Kelapa Sawit," vol. 7, no. 1, hlm. 54-62, Juni 2025.