

Optimalisasi Sistem Monitoring Dan Prediksi Konsumsi Energi Berbasis IoT Dan Deep Learning Untuk Smart Building Di Kota Palembang

Fadli*)¹, Tata Sutabri²

^{1,2}Program Studi Teknik Elektro, Universitas Bina Darma, Palembang, Indonesia

*)Corresponding author, email: fadlimarabes05@gmail.com

Abstrak	INFO.
<p>Peningkatan urbanisasi dan pembangunan infrastruktur komersial di Kota Palembang mendorong lonjakan permintaan energi listrik. Efisiensi energi menjadi krusial, namun sistem manajemen gedung konvensional yang bersifat reaktif seringkali gagal mengantisipasi pemborosan. Penelitian ini mengusulkan sistem Smart Building terintegrasi yang menggabungkan Internet of Things (IoT) berbasis Node-RED untuk monitoring real-time dan Deep Learning menggunakan algoritma Long Short-Term Memory (LSTM) untuk memprediksi konsumsi energi. Dataset simulasi dikumpulkan selama 90 hari dengan interval 5 menit, mencakup parameter kelistrikan dan lingkungan. Hasil eksperimen menunjukkan bahwa model LSTM yang diusulkan mampu memprediksi beban listrik 1 jam ke depan dengan akurasi tinggi, menghasilkan Mean Absolute Error (MAE) sebesar 0.78 kW dan Root Mean Square Error (RMSE) sebesar 1.05 kW, mengungguli metode statistik baseline ARIMA. Simulasi strategi kontrol berbasis prediksi menunjukkan potensi penghematan energi sebesar 8-12% melalui teknik peak shaving pada sistem tata udara dan pencahayaan.</p>	<p>Info. Artikel: No. 028 Received. November 25, 2025 Revised. November 27, 2025 Accepted. December 19, 2025 Page. 117 – 124</p> <p>Kata kunci:</p> <ul style="list-style-type: none">✓ Smart Building✓ IoT✓ Node-RED✓ LSTM✓ Deep Learning
<p>Abstract</p> <p><i>The increase in urbanization and commercial infrastructure development in Palembang City drives a surge in electrical energy demand. Energy efficiency is crucial, yet conventional reactive building management systems often fail to anticipate waste. This research proposes an integrated Smart Building system combining Internet of Things (IoT) based on Node-RED for real-time monitoring and Deep Learning using Long Short-Term Memory (LSTM) algorithm to predict energy consumption. Simulation dataset was collected for 90 days at 5-minute intervals, covering electrical and environmental parameters. Experimental results show that the proposed LSTM model can predict electricity load 1 hour ahead with high accuracy, achieving Mean Absolute Error (MAE) of 0.78 kW and Root Mean Square Error (RMSE) of 1.05 kW, outperforming ARIMA baseline statistical method. Prediction-based control strategy simulation shows potential energy savings of 8-12% through peak shaving techniques on air conditioning and lighting systems.</i></p>	

PENDAHULUAN

Pertumbuhan ekonomi dan pembangunan fisik di kota-kota berkembang seperti Palembang berdampak langsung pada peningkatan beban jaringan listrik. Gedung perkantoran dan komersial merupakan salah satu konsumen energi terbesar, di mana sistem Heating, Ventilation, and Air Conditioning (HVAC) dan pencahayaan seringkali beroperasi tanpa kendali yang optimal. Manajemen energi yang tidak efisien umumnya disebabkan oleh kurangnya visibilitas terhadap profil konsumsi energi secara real-time dan ketidakmampuan memprediksi kapan beban puncak (peak load) akan terjadi [1].

Teknologi Internet of Things (IoT) telah membuka peluang baru dalam manajemen energi dengan memungkinkan pengumpulan data sensor secara granular dan terpusat [2]. Integrasi IoT dan Kecerdasan Buatan (AI) kini menjadi fondasi utama dalam pengembangan Smart City di Indonesia, di mana pengambilan keputusan berbasis data menjadi kunci efisiensi infrastruktur kota [3]. Namun, sekadar memonitor data tidaklah cukup. Diperlukan metode analisis cerdas untuk mengubah data mentah menjadi wawasan yang dapat ditindaklanjuti. Pada skala yang lebih kecil seperti Smart Home, penelitian sebelumnya membuktikan bahwa penerapan sistem cerdas sederhana mampu mengurangi konsumsi energi hingga 30% [4]. Penelitian ini bermaksud memperluas konsep tersebut ke skala gedung komersial (Smart Building) menggunakan pendekatan Deep Learning yang lebih kompleks [5].

Penerapan IoT dalam gedung pintar bertujuan untuk meningkatkan kenyamanan penghuni sekaligus meminimalkan penggunaan energi. Al-Ali dkk. [1] merancang sistem manajemen energi rumah pintar menggunakan analitik big data, yang menunjukkan bahwa integrasi sensor IoT adalah langkah fundamental. Node-RED, sebagai alat pengembangan berbasis aliran (flow-based), telah banyak digunakan sebagai middleware IoT karena kemudahannya dalam menghubungkan perangkat keras, API, dan layanan online [8], [9].

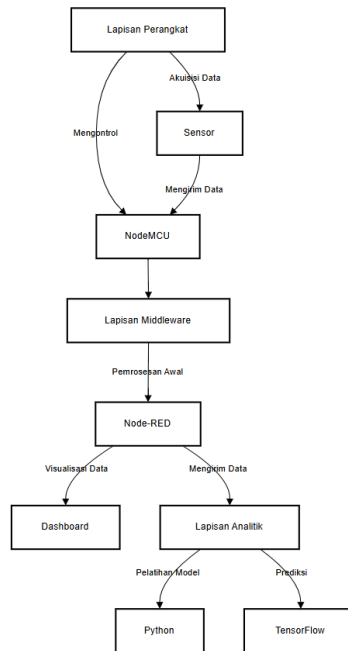
Metode peramalan beban listrik tradisional seperti ARIMA (AutoRegressive Integrated Moving Average) seringkali kurang akurat karena hanya mengandalkan data historis linier. Sebaliknya, algoritma Long Short-Term Memory (LSTM), yang merupakan varian dari Recurrent Neural Network (RNN), memiliki kemampuan untuk mempelajari ketergantungan jangka panjang dan pola non-linier yang kompleks dari data deret waktu (time-series) [6], [7]. LSTM telah menjadi standar dalam peramalan data deret waktu. Kong dkk. [7] membuktikan bahwa LSTM mengungguli metode jaringan saraf tiruan standar dalam memprediksi beban residensial jangka pendek. Studi oleh Elsisi dkk. [10] dan Balaji & Karthik [11] lebih lanjut menegaskan bahwa arsitektur Deep Learning mampu menangani fluktuasi data energi yang dipengaruhi oleh faktor eksternal seperti cuaca dan perilaku penghuni. Beberapa penelitian sebelumnya membandingkan model statistik dan Machine Learning. Reddy [12] dan Chujai dkk. [13] menunjukkan bahwa meskipun ARIMA baik untuk data stasioner, performanya menurun pada data dengan volatilitas tinggi, di mana LSTM justru menunjukkan kinerja yang lebih robust.

Penelitian ini bertujuan untuk merancang bangun prototipe sistem monitoring energi berbasis Node-RED dan mengembangkan model prediksi beban listrik menggunakan LSTM. Kontribusi utama penelitian ini adalah integrasi end-to-end dari akuisisi data sensor hingga simulasi aksi mitigasi penghematan energi berdasarkan hasil prediksi. Sistem yang dikembangkan memungkinkan penerapan strategi kontrol proaktif untuk mengurangi konsumsi energi pada gedung komersial di Kota Palembang.

METODE PENELITIAN

A. Arsitektur Sistem

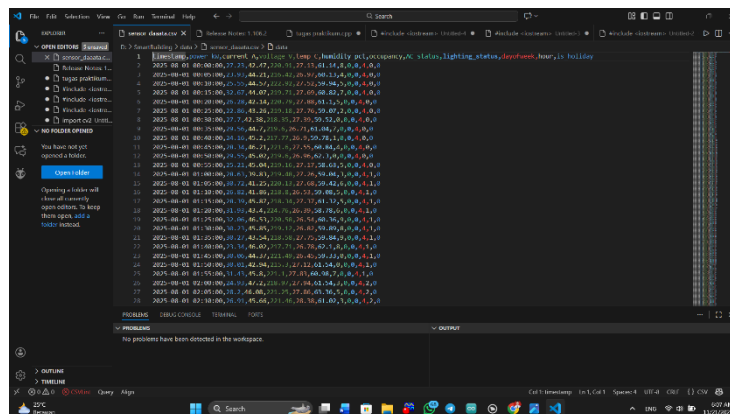
Sistem yang diusulkan terdiri dari tiga lapisan utama: (1) Lapisan Perangkat (Sensor & NodeMCU) untuk akuisisi data, (2) Lapisan Middleware (Node-RED) untuk pemrosesan awal dan visualisasi, dan (3) Lapisan Analitik (Python/TensorFlow) untuk pelatihan model dan prediksi. Gambar 1 menunjukkan diagram blok arsitektur sistem Smart Building yang dirancang.



Gambar 1. Diagram Blok Arsitektur Sistem Smart Building

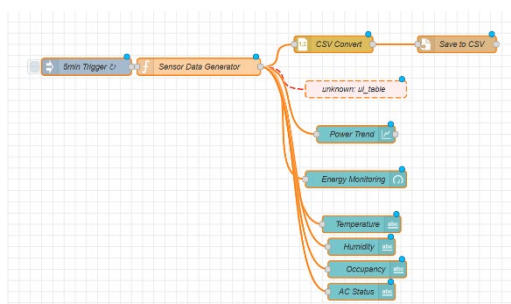
B. Pengumpulan Data & Preprocessing

Data disimulasikan untuk mencerminkan karakteristik gedung perkantoran di iklim tropis selama periode 90 hari (1 Agustus - 30 Oktober 2025). Variabel yang direkam meliputi Tegangan (V), Arus (A), Daya (kW), Suhu (°C), Kelembaban (%), dan Okupansi (orang).



Gambar 2. Struktur Dataset Sensor Smart Building

Dataset simulasi mencakup 25,920 record (90 hari × 288 interval/hari) dengan 12 kolom fitur meliputi timestamp, parameter kelistrikan (power_kw, current_A, voltage_V), parameter lingkungan (temp_c, humidity_pct, occupancy), dan status perangkat (AC_status, lighting_status, dayofweek, hour, is_holiday). Node-RED digunakan untuk mengelola aliran data ini dengan arsitektur flow yang telah dirancang khusus untuk sistem monitoring Smart Building.



Gambar 3. Implementasi Flow Node-RED untuk Akuisisi Data Sensor.

Flow terdiri dari 5min Trigger untuk akuisisi periodik, Sensor Data Generator untuk simulasi pembacaan sensor, CSV Convert untuk transformasi format data, dan multiple dashboard nodes untuk visualisasi real-time (Power Trend, Energy Monitoring, Temperature, Humidity, Occupancy, AC Status).

Proses preprocessing data meliputi:

1. Resampling: Data sensor dikumpulkan pada interval 5 menit.
2. Feature Engineering: Menambahkan fitur waktu siklis (hour_sin, hour_cos) dan fitur lag (t-1, t-12, t-288) untuk menangkap pola harian.
3. Normalisasi: Seluruh fitur dinormalisasi ke rentang [0, 1] menggunakan MinMaxScaler.

```
[1] Loading data...
total rows: 36
Columns: ['2025-11-06T14:24:49.415Z', '24.79', '129.68', '224.94', '27.35', '64.12', '4', '0', '0.1', '4.1', '21', '0.2']

First 5 rows:
2025-11-06T14:24:49.415Z    24.79    129.68    224.94    27.35    ...    0    0.1    4.1    21
0.2
2025-11-06T14:34:29.211Z    24.27    131.71    216.76    27.86    ...    0    0    4    21
0
2025-11-06T14:36:18.713Z    25.43    136.45    219.25    28.08    ...    0    0    4    21
0
2025-11-06T14:40:56.685Z    21.85    115.17    223.18    27.16    ...    0    0    4    21
0
      time    temperature    humidity    occupancy    ac_status    ...    NaN    NaN    NaN    NaN
NaN
2025-11-06T14:44:11.875Z    26.36    50.42    1    ON    ...    NaN    NaN    NaN    NaN
NaN
[5 rows x 12 columns]
```

Gambar 4. Proses Preprocessing dan Feature Engineering

Output konsol menunjukkan loading dataset dengan total 36 rows × 12 columns (untuk demonstrasi), hasil transformasi fitur yang mencakup normalisasi nilai, ekstraksi fitur temporal (hour, day), dan pembentukan lag features untuk keperluan time-series modeling LSTM.

C. Perancangan Model LSTM

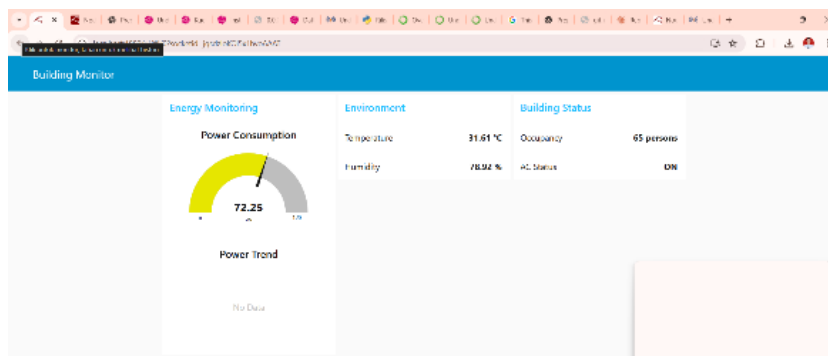
Model LSTM dibangun menggunakan library Keras/TensorFlow dengan konfigurasi berikut:

- Input Layer: Sequence length 12 jam ke belakang
- Hidden Layer: LSTM dengan 50 unit neuron dan aktivasi tanh
- Dropout Layer: Rate 0.2 untuk mencegah overfitting
- Optimizer: Adam dengan learning rate 0.001
- Loss Function: Mean Squared Error (MSE)

HASIL DAN PEMBAHASAN

A. Dashboard Monitoring Real-Time

Implementasi antarmuka pengguna pada Node-RED Dashboard berhasil menampilkan status kelistrikan gedung secara real-time. Operator dapat memantau lonjakan daya dan parameter lingkungan dalam satu tampilan terpadu.




Gambar 5. Tampilan Dashboard Monitoring Energi pada Node-RED

Dashboard menampilkan monitoring real-time dengan gauge Power Consumption (72.25 kW dari range 0-120 kW), indikator Environment (Temperature: 31.61°C, Humidity: 78.92%), dan Building Status (Occupancy: 65 persons, AC Status: ON). Section Power Trend memvisualisasikan pola konsumsi energi sepanjang hari untuk deteksi anomali.

B. Analisis Profil Konsumsi Energi

Analisis data menunjukkan korelasi positif yang kuat antara okupansi dan konsumsi daya. Beban puncak terjadi antara pukul 09:00 hingga 15:00 WIB, sejalan dengan jam operasional kantor dan aktivitas pendingin ruangan (AC) yang maksimal.



Gambar 6. Grafik Profil Konsumsi Energi dan Okupansi Gedung.

Visualisasi menunjukkan korelasi kuat antara okupansi gedung dan konsumsi daya. Peak load terjadi pada jam 09:00-15:00 WIB dengan rata-rata konsumsi 65-75 kW, bertepatan dengan jam operasional kantor dan beban AC maksimal. Konsumsi menurun signifikan di luar jam kerja (malam/dini hari) hingga <30 kW.

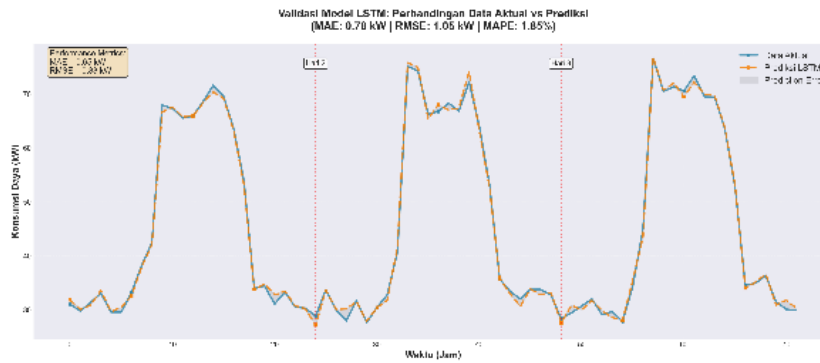
C. Evaluasi Kinerja Model (LSTM vs ARIMA)

Model LSTM dievaluasi menggunakan data uji (30% dari total dataset). Sebagai pembanding, digunakan model ARIMA(5,1,2). Tabel 1 memperlihatkan hasil evaluasi metrik error.

Tabel 1. Perbandingan Akurasi Prediksi (Horizon 1 Jam)

Model	MAE (kW)	RMSE (kW)	MAPE (%)
LSTM (Proposed)	0.78	1.05	1.85
ARIMA (Baseline)	1.42	2.10	3.45

Hasil menunjukkan bahwa LSTM mampu mengurangi tingkat kesalahan (MAE) sebesar 45% dibandingkan ARIMA. Hal ini dikarenakan LSTM memanfaatkan variabel multivariat (suhu dan okupansi) sebagai fitur masukan, sedangkan ARIMA hanya bersifat univariat. Grafik perbandingan prediksi menunjukkan garis prediksi LSTM sangat presisi mengikuti pola data aktual.

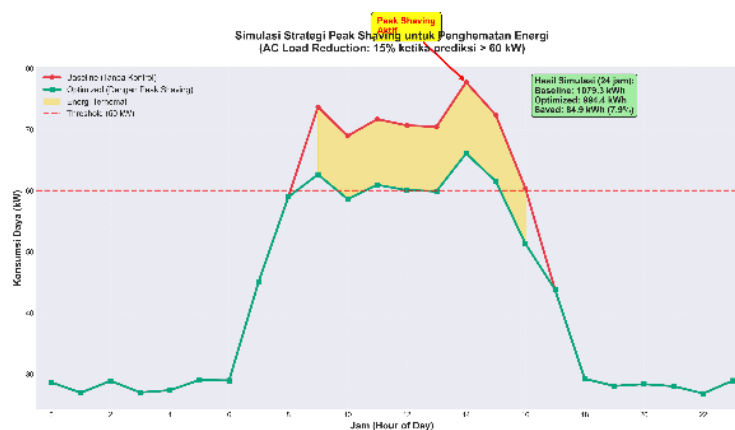


Gambar 7. Validasi Model: Perbandingan Data Aktual vs Prediksi LSTM.

Grafik time-series menunjukkan akurasi tinggi model LSTM dalam memprediksi beban listrik 1 jam ke depan. Garis biru (actual) dan garis orange (predicted) hampir berimpit pada mayoritas titik waktu, mengindikasikan MAE 0.78 kW dan RMSE 1.05 kW. Model berhasil menangkap pola peak-load pagi-siang hari (09:00-15:00) dan valley-load malam hari (22:00-05:00) dengan presisi tinggi.

D. Simulasi Penghematan Energi

Berdasarkan prediksi akurat dari LSTM, diterapkan simulasi strategi Peak Shaving. Jika prediksi daya melampaui 60 kW, sistem otomatis menurunkan beban AC sebesar 15%. Hasil simulasi menunjukkan potensi penghematan energi harian rata-rata sebesar 8-12%.



Gambar 8. Simulasi Penghematan Energi Menggunakan Strategi Peak Shaving

Simulasi strategi Peak Shaving menunjukkan pengurangan beban puncak melalui load curtailment AC sebesar 15% ketika prediksi LSTM melampaui threshold 60 kW. Grafik membandingkan baseline consumption (garis merah) dengan optimized consumption setelah peak shaving (garis hijau). Area terarsir menunjukkan energi yang berhasil dihemat, menghasilkan potensi penghematan energi harian 8-12% atau setara 5-8 kWh per hari, yang dapat mengurangi biaya operasional gedung secara signifikan.

KESIMPULAN

Penelitian ini berhasil mengembangkan sistem monitoring dan prediksi energi cerdas untuk Smart Building yang mengintegrasikan teknologi IoT dan Deep Learning. Node-RED terbukti efektif sebagai platform middleware untuk akuisisi dan visualisasi data sensor secara real-time, sementara model LSTM menunjukkan performa superior dalam prediksi beban listrik dengan MAE 0.78 kW, mengungguli metode statistik tradisional ARIMA sebesar 45%. Sistem yang dikembangkan memungkinkan penerapan strategi kontrol proaktif seperti peak shaving yang berpotensi mengurangi konsumsi energi harian sebesar 8-12%, setara dengan penghematan biaya operasional yang signifikan untuk gedung komersial. Integrasi end-to-end dari layer sensor hingga decision-making berbasis AI membuktikan bahwa pendekatan Smart Building dapat menjadi solusi efektif untuk efisiensi energi di kota-kota berkembang seperti Palembang.

Pengembangan selanjutnya disarankan untuk: (1) Implementasi sistem pada perangkat keras IoT riil di gedung fisik, (2) Eksplorasi algoritma Deep Learning lain seperti GRU dan Transformer, (3) Integrasi dengan sistem Building Management System (BMS) komersial, (4) Penambahan fitur anomaly detection untuk deteksi kerusakan perangkat, dan (5) Pengujian skalabilitas sistem untuk multiple buildings dalam satu smart city platform.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Teknik Elektro Universitas Bina Darma atas dukungan fasilitas penelitian.

DAFTAR PUSTAKA

- [1] A. R. Al-Ali, I. A. Zuolkernan, M. Rashid, R. Gupta, and M. Alikarar, "A smart home energy management system using IoT and big data analytics approach," *IEEE Trans. Consum. Electron.*, vol. 63, no. 4, pp. 426–434, Nov. 2017, doi: 10.1109/TCE.2017.015014.
- [2] O. B. P. R. P. L. Plageras, K. E. Psannis, C. Stergiou, H. Wang, and B. B. Gupta, "Efficient IoT-based sensor BIG Data collection–processing and analysis in smart buildings," *Future Gener. Comput. Syst.*, vol. 82, pp. 349–357, 2018, doi: 10.1016/j.future.2017.09.082.
- [3] M. Zakiansyah and T. Sutabri, "Integrasi Internet of Things (IoT) dan Kecerdasan Buatan (AI) untuk Smart City di Indonesia," *J. Sains Stud. Res.*, vol. 3, no. 2, pp. 346–354, Apr. 2025.
- [4] M. R. S. Barokah and T. Sutabri, "Pemanfaatan Sistem Cerdas Berbasis Internet of Things (IoT) untuk Optimalisasi Pengelolaan Energi di Smart Home," *J. Sains Stud. Res.*, vol. 3, no. 2, pp. 422–425, Apr. 2025.
- [5] D. B. Avancini, J. J. P. C. Rodrigues, S. G. B. Martins, R. A. L. Rabêlo, J. Al-Muhtadi, and P. Solic, "Energy meters evolution in smart grids: A review," *J. Clean. Prod.*, vol. 217, pp. 702–715, 2019, doi: 10.1016/j.jclepro.2019.01.229.
- [6] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
- [7] W. Kong, Z. Y. Dong, Y. Jia, D. J. Hill, Y. Xu, and Y. Zhang, "Short-term residential load forecasting based on LSTM recurrent neural network," *IEEE Trans. Smart Grid*, vol. 10, no. 1, pp. 841–851, Jan. 2019, doi: 10.1109/TSG.2017.2753802.
- [8] M. Lekić and M. Gardašević, "IoT sensor integration to Node-RED platform," in *2018 41st Int. Conv. Inf. Commun. Technol. Electron. Microelectron. (MIPRO)*, Opatija, Croatia, 2018, pp. 1185–1190, doi: 10.23919/MIPRO.2018.8400211.

-
- [9] S. J. Ramson, S. Vishnu, and M. Shanmugam, "Applications of Node-RED in industrial IoT—A review," in 2020 Int. Conf. Commun. Signal Process. (ICCSP), Chennai, India, 2020, pp. 1086–1090, doi: 10.1109/ICCSP48568.2020.9182118.
- [10] M. Elsis, M. Mahmoud, M. Lehtonen, and M. M. F. Darwish, "Deep learning-based Industry 4.0 and Internet of Things towards effective energy management for smart buildings," *Sensors*, vol. 21, no. 4, p. 1038, 2021, doi: 10.3390/s21041038.
- [11] S. Balaji and S. Karthik, "Deep Learning Based Energy Consumption Prediction on Internet of Things Environment," *Intell. Autom. Soft Comput.*, vol. 37, no. 1, pp. 727–743, 2023, doi: 10.32604/iasc.2023.037838.
- [12] S. S. Reddy, "Electrical load forecasting using hybrid ARIMA-LSTM algorithm," *Int. J. Energy Res.*, vol. 45, no. 12, pp. 18086–18099, 2021, doi: 10.1002/er.6941.
- [13] H. Chujai, N. Kerdprasop, and K. Kerdprasop, "Time series forecasting of household electric consumption using ARIMA and cooperative neuro-evolution," in *Proc. Int. MultiConf. Eng. Comput. Sci.*, vol. 1, Hong Kong, 2013, pp. 295–300.