

# PREDIKSI KONSUMSI LISTRIK BANGUNAN GEDUNG MENGGUNAKAN MODEL LSTM UNTUK EFISIENSI ENERGI DAN MITIGASI LINGKUNGAN

Ahmad Rofii<sup>1</sup>, Muhammad Sobirin<sup>1</sup>, Jemie Muliadi<sup>1</sup>

Fakultas Teknik dan Informatika, Universitas 17 Agustus 1945 Jakarta, Jakarta 14350, Indonesia  
[rofii.ahmad@uta45jakarta.ac.id](mailto:rofii.ahmad@uta45jakarta.ac.id)

## ABSTRAK

Penggunaan daya listrik di sektor bangunan gedung merupakan salah satu penyumbang terbesar dalam konsumsi energi dan dampak lingkungan. Oleh karena itu penggunaan listrik harus terencana, perencanaan perlu memprediksi kondisi dimasa akan datang. model LSTM relevan untuk memprediksi data time series, pada penelitian ini data *time series* penggunaan daya listrik yang digunakan berasal dari *platform kaggle.com* dengan data yang terdiri dari 525598 baris dan 11 fitur, penelitian ini bertujuan untuk mendapatkan hasil prediksi penggunaan daya pada peralatan pada bangunan gedung. Metrik kinerja yang digunakan, termasuk *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE), menunjukkan bahwa model LSTM dapat menangkap pola penggunaan daya listrik secara efektif. Hasil penelitian ini tidak hanya memberikan wawasan tentang perilaku konsumsi energi, tetapi juga berkontribusi pada upaya mitigasi lingkungan dengan memungkinkan pengelolaan energi yang lebih efisien. Dengan memprediksi konsumsi listrik secara akurat, manajemen pengelola dapat mengambil langkah-langkah untuk mengurangi pemborosan energi, mengoptimalkan penggunaan sumber daya, dan meminimalkan dampak negatif terhadap lingkungan. Penelitian ini menekankan pentingnya integrasi teknologi prediksi dalam strategi manajemen energi untuk mencapai keberlanjutan yang lebih baik.

**Kata kunci :** Komsumsi daya listrik, Prediksi energi, Bangunan Gedung, model LSTM, *Time series*

## ABSTRACT

*Electricity usage in the building sector is one of the largest contributors to energy consumption and environmental impact. Therefore, electricity usage must be carefully planned, with future conditions predicted as part of the planning process. The Long Short-Term Memory (LSTM) model is particularly relevant for forecasting time-series data. In this study, time-series data on electricity consumption was sourced from Kaggle.com, consisting of 525,598 rows and 11 features. The research aims to produce accurate predictions of electricity usage for building equipment. Performance metrics, including Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and Mean Absolute Percentage Error (MAPE), indicate that the LSTM model effectively captures the patterns of electricity usage. The findings provide not only valuable insights into energy consumption behavior but also contribute to environmental mitigation efforts by enabling more efficient energy management. By accurately predicting electricity consumption, energy managers can implement strategies to reduce waste, optimize resource usage, and minimize negative environmental impacts. This study underscores the importance of integrating predictive technologies into energy management strategies to achieve greater sustainability.*

**Keywords:** Electricity consumption, Energy prediction, Building sector, LSTM model, Time series

## PENDAHULUAN

Bangunan dapat diklasifikasikan ke dalam berbagai jenis struktur berdasarkan volume, bentuk, dan tujuannya. Berdasarkan studi komprehensif yang dilakukan oleh Zhang et al. [1], prediksi beban energi bangunan telah menjadi fokus utama dalam penelitian terkait efisiensi energi dan keberlanjutan. Menurut Wang et al. [2], bangunan komersial dan residensial mengkonsumsi sekitar 40% dari total energi global dan berkontribusi signifikan terhadap emisi gas rumah kaca. Setiap jenis bangunan menunjukkan pola konsumsi listrik yang berbeda tergantung pada penggunaannya, yang membuat prediksi permintaan listrik menjadi tantangan kompleks dalam manajemen energi. Studi terbaru oleh Rahman et al. [3] menunjukkan bahwa bangunan komersial dan residensial memiliki karakteristik beban yang unik dan pola okupansi yang berbeda antara hari kerja dan hari libur. Massana et al. [4] mengonfirmasi bahwa atribut okupansi buatan memainkan peran kritis dalam akurasi prediksi beban jangka pendek untuk bangunan non-residensial. Pemahaman tentang pola ini sangat penting untuk pengembangan model prediksi yang akurat.

Dalam konteks efisiensi energi, Daut et al. [5] melakukan tinjauan komprehensif terhadap metode konvensional dan kecerdasan buatan dalam peramalan konsumsi energi listrik bangunan. Mereka menemukan bahwa pendekatan *machine learning* (pembelajaran mesin) modern mengungguli metode konvensional dalam hal akurasi dan kemampuan adaptasi. Ahmad et al. [6] lebih lanjut menggarisbawahi pentingnya *machine learning* dalam meramalkan tren pertumbuhan energi dan aplikasi waktu nyata mereka dalam berbagai sistem energi. Merespons tantangan ini, penelitian terbaru oleh Fan et al. [7] dan Kim & Cho [8] mendemonstrasikan keefektifan arsitektur *deep learning*, khususnya CNN-LSTM, dalam memprediksi konsumsi energi residensial. Berdasarkan temuan-temuan tersebut, penelitian ini mengusulkan penggunaan *Deep Recurrent Neural Network (DRNN)* untuk prediksi konsumsi energi bangunan. Pendekatan ini dibangun di atas keberhasilan yang dilaporkan oleh Le et al. [9], yang menggunakan strategi berbasis cluster untuk *transfer learning* dalam *smart building* (bangunan pintar). Model yang diusulkan akan dievaluasi menggunakan metrik standar seperti *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE) untuk memastikan keandalan dan akurasi prediksi.

## METODE

### Manfaat Prediksi Konsumsi Energi Bangunan

Model prediksi konsumsi energi menawarkan sejumlah keuntungan strategis yang signifikan dalam manajemen energi modern. Menurut Ahmad et al. [6], teknologi prediksi memungkinkan pengelolaan energi yang lebih efisien, terutama selama beban puncak, yang memungkinkan pemangku kepentingan untuk mengurangi biaya dan meningkatkan efisiensi penggunaan energi. Wang et al. [2] menegaskan bahwa prediksi akurat tentang konsumsi energi menghasilkan keputusan yang lebih baik dalam mengantisipasi fluktuasi penggunaan listrik masa depan. Hal ini memungkinkan organisasi untuk mengambil langkah-langkah proaktif dalam penghematan energi, merencanakan konsumsi energi listrik secara strategis dan mengoptimalkan alokasi sumber daya energi. Kemudian, data prediksi juga dapat digunakan sebagai dasar untuk strategi manajemen energi yang lebih

efektif, membantu organisasi dalam perencanaan dan optimalisasi penggunaan energi. Penelitian oleh Rahman et al. [3] menunjukkan bahwa pengelolaan konsumsi energi yang lebih efisien dapat secara signifikan mengurangi dampak negatif terhadap lingkungan. Kim & Cho [8] menekankan bahwa model prediksi berkontribusi pada upaya keberlanjutan dengan mengurangi emisi gas rumah kaca, mengoptimalkan penggunaan sumber daya energi serta mendukung transisi menuju infrastruktur energi yang lebih berkelanjutan. Fan et al. [7] menekankan bahwa model prediksi berfungsi sebagai alat analitis yang kuat untuk memahami pola konsumsi energi. Melalui model ini, organisasi dapat mengidentifikasi faktor-faktor yang mempengaruhi konsumsi energi, memperoleh wawasan mendalam tentang perilaku pengguna dan mengembangkan strategi efisiensi yang disesuaikan. Sebagaimana digarisbawahi oleh Zhang et al. [1], metode prediksi yang diusulkan memberikan manfaat signifikan dalam hal efisiensi, pengambilan keputusan, dan keberlanjutan dalam manajemen energi bangunan.

### Model Prediksi

Kemajuan teknologi telah secara signifikan meningkatkan akurasi prediksi untuk berbagai jenis data, termasuk data deret waktu numerik seperti penggunaan daya listrik di bangunan. Menurut Ahmad et al. [6], pola data kompleks ini dapat diolah secara efektif menggunakan teknologi *machine learning* dan *deep learning*, khususnya *neural network*, untuk menghasilkan prediksi yang lebih akurat dibandingkan dengan metode konvensional. Zhang et al. [1] menegaskan bahwa kemampuan *deep learning* telah membuka peluang baru dalam prediksi beban bangunan dengan tingkat presisi yang lebih tinggi. *Recurrent Neural Network* (RNN) merupakan metode *deep learning* yang meniru kemampuan pengambilan keputusan manusia dengan menyimpan informasi historis dan memproses data secara sekuensial. Zhao et al. [10] menjelaskan bahwa RNN memiliki kemampuan unik dalam mempertahankan hubungan temporal antar data, yang sangat penting dalam prediksi konsumsi energi. Penelitian oleh Wang et al. [2] mendemonstrasikan efektivitas RNN dalam merepresentasikan hubungan kompleks antara neuron dan fitur dalam berbagai aplikasi prediksi beban termal bangunan. *Long Short-Term Memory* (LSTM), sebagai arsitektur RNN yang canggih, dirancang khusus untuk menangani hubungan data yang terpisah dalam urutan panjang. Seperti yang dijelaskan oleh Kim & Cho [7], LSTM memiliki beberapa komponen kunci:

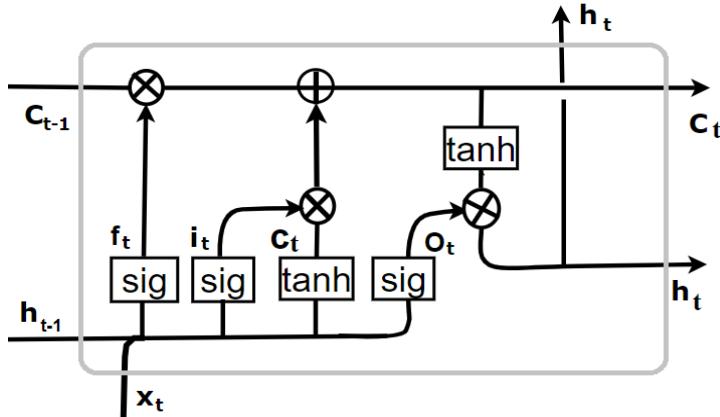
1. *Cell state* sebagai mekanisme penyimpanan informasi jangka panjang
2. Sistem *gate* yang mengatur aliran informasi
3. Algoritma *Backpropagation Through Time* (BPTT) untuk pembaruan model
4. Memori jangka pendek yang memproses informasi baru di setiap langkah waktu

Fan et al. [7] menjelaskan bahwa arsitektur LSTM menggunakan tiga jenis *gate* utama:

- *Input gate*: mengontrol informasi baru yang akan disimpan dalam *cell state*
- *Output gate*: menentukan bagian dari *cell state* yang akan dikeluarkan
- *Forget gate*: mengatur informasi yang perlu dihapus dari *cell state*

Le et al. [9] mendemonstrasikan bahwa struktur *gate* ini memungkinkan LSTM untuk secara selektif mengingat atau melupakan informasi, membuat model sangat efektif dalam memprediksi pola konsumsi energi jangka panjang. Rahman et al. [3] lebih lanjut

membuktikan keunggulan LSTM dalam prediksi konsumsi listrik bangunan komersial dan residensial, dengan kemampuan untuk menangkap pola musiman dan tren jangka panjang.



Gambar 1. Arsitektur LSTM

Berikut gerbang-gerbang pada LSTM beserta formula perhitungannya.

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

$$\text{Input gate} \quad i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\text{Cell state} \quad C_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$\text{Hidden state} \quad h_t = o_t \cdot \tanh(C_t) \quad (4)$$

### Penggunaan listrik pada Bangunan

Pola penggunaan listrik pada bangunan gedung memiliki karakteristik yang kompleks dan bervariasi, bergantung pada peruntukan, desain, dan operasional gedung tersebut. Berdasarkan penelitian yang dilakukan oleh Zhang et al. [11], konsumsi energi pada bangunan residensial perkotaan menunjukkan pola yang berbeda berdasarkan zona iklim, waktu operasional, dan perilaku penghuni. Studi tersebut mengidentifikasi bahwa 45-55% konsumsi energi digunakan untuk sistem HVAC, 20-25% untuk peralatan rumah tangga, dan 15-20% untuk sistem penerangan. Dalam konteks manajemen energi, Patel dan Singh [12] mengungkapkan bahwa implementasi sistem manajemen energi cerdas dapat mengoptimalkan penggunaan energi dengan mempertimbangkan berbagai pola beban. Sistem ini mampu mengklasifikasikan beban berdasarkan durasi penggunaan:

- *Long temporary* (8-12 jam): Sistem HVAC dan penerangan utama
- *Short temporary* (2-4 jam): Peralatan kantor dan aplikasi khusus
- *Continues temporary* (24 jam): Sistem keamanan dan peralatan kritis
- *Zig-zag temporary*: Peralatan dengan penggunaan *intermittent*

Li et al. [13] mendemonstrasikan bahwa pola konsumsi energi dapat diprediksi dengan akurasi hingga 92% menggunakan pendekatan *machine learning*. Penelitian ini mengidentifikasi bahwa setiap tipe beban memiliki karakteristik daya aktif dan reaktif yang berbeda:

- Sistem HVAC: *Power factor* 0.85-0.90
- Sistem Penerangan: *Power factor* 0.95-0.98
- Peralatan Elektronik: *Power factor* 0.65-0.75

Martinez dan Rodriguez [14] menekankan pentingnya monitoring *real-time* untuk mengoptimalkan penggunaan energi. Penelitian mereka menunjukkan bahwa implementasi sistem monitoring lanjutan dapat menghasilkan penghematan energi sebesar 15-30% melalui optimasi jadwal operasional peralatan, deteksi anomali konsumsi energi, manajemen beban puncak, serta kontrol adaptif berdasarkan okupansi. Lee et al. [15] menganalisis pola konsumsi spesifik pada bangunan pendidikan. Penelitian ini mengungkapkan bahwa 40% konsumsi energi terjadi selama jam operasional utama (08.00-16.00), 25% konsumsi terjadi pada periode transisi (16.00-20.00), dan 35% konsumsi tersebar pada periode lainnya. Pola resultan yang kompleks pada konsumsi daya total terbentuk dari interaksi berbagai beban dengan karakteristik temporal yang berbeda. Hal ini menghasilkan kurva beban yang bervariasi sepanjang hari, dengan puncak-puncak konsumsi yang dapat diprediksi namun tetap memerlukan strategi manajemen yang komprehensif untuk optimasi penggunaan energi.

## Dataset

Pengukuran Penggunaan daya listrik suatu bangunan gedung menghasilkan sebuah Dataset time seris dari daya atau parameter listrik yang diukur dalam setiap menit, jam 12 jam atau 24 jam. Dalam penelitian ini dataset yang digunakan adalah dataset yang diambil dari platform kaggle.com. Dataset ini adalah dataset primer karena data ini berasal kumpulan hasil pengukuran melalui smart meter. merupakan data hasil pengukuran besaran listrik pada Gedung Akademik Universitas chulalongkorn. Pelaksanaan pengukuran besaran listrik ini dilakukan secara kontinu dalam setiap menit mulai dari 1 Januari pukul 11.59 hingga 31 Desember 2019 pukul 24.00. Pengukuran pada dataset ini dilakukan pada tiga saluran listrik yaitu saluran listrik untuk Airconditioning yang terdiri dari 4 titik pengukuran, Saluran listrik stop kontak (Plug) yang terdiri dari 3 titik lokasi pengukuran dan pada saluran listrik penerangan yang terdiri dari 4 titik lokasi pengukuran. Total pengukuran adalah 11 lokasi dengan time step pengukuran sebanyak 525599 time step.

## Pengumpulan Data

Tabel 1. Dataset pengukuran lampu, AC, Plug yang bersumber dari Kaggle.com

	Date	Lamp_1	Plug_1	AC1	AC2	AC3	AC4	Lamp_2	Plug_2	Lamp_3	Plug_3	Lamp_4
0	01/01/2019 00:00	0.03	0.58	2.31	21.15	0.01	0.02	17.37	15.2	10.01	0.38	14.58
1	01/01/2019 00:01	0	0.58	2.31	35.07	0	0.02	17.34	19.16	9.98	0.37	14.57
2	01/01/2019 00:02	0.02	0.58	30.96	34.37	0.01	0.03	17.31	19.02	9.98	0.38	14.62
4	01/01/2019 00:04	0.01	0.56	48.87	1.35	0.01	0.01	17.48	18.57	10.05	0.38	14.6
;	;	;	;	;	;	;	;	;	;	;	;	;
525597	2019-12-31 23:57:00	0.01	0.01	51.20	0.03	0.01	0.01	8.90	20.62	11.03	1.24	18.30
525598	2019-12-31 23:58:00	0.01	0.01	40.38	0.03	0.00	0.00	8.87	17.81	11.03	1.25	18.28
525599	2019-12-31 23:59:00	0.01	0.00	2.23	0.03	0.01	0.00	8.88	17.44	11.00	1.26	18.30

Tabel 2 ini memperlihatkan hasil pengukuran yang diunduh dari *kaggle.com* hasil penguluran dari lampu 1 hingga 4, hasil pengukuran AC 1 hingga AC4 dan Pengukuran pada *Plug* 1 hingga 3 dalam setiap menit (*time step*).

### 1. Pengumpulan Data

Data yang digunakan dalam penelitian ini diambil dari *platform Kaggle.com*, yang merupakan salah satu sumber data terbuka terbesar di dunia. Dataset yang dipilih berfokus pada konsumsi daya listrik di bangunan gedung, mencakup informasi penggunaan listrik dalam interval waktu tertentu. Dataset ini terdiri dari baris data yang merepresentasikan konsumsi daya listrik dengan 525598 baris 11 fitur, dengan muatan waktu pengukuran, jenis peralatan, dan nilai konsumsi listrik.

Proses pengumpulan data dimulai dengan pencarian dataset yang sesuai di Kaggle menggunakan kata kunci terkait seperti "*energy consumption*" dan "*electricity usage*". Setelah menemukan dataset yang relevan, peneliti melakukan evaluasi awal terhadap kualitas dan kelengkapan data, memastikan bahwa data tersebut mencakup rentang waktu yang cukup dan memiliki variabel yang diperlukan untuk analisis. Setelah dataset diunduh, langkah selanjutnya adalah melakukan pemeriksaan awal untuk mengidentifikasi adanya nilai yang hilang (*missing values*) atau anomali dalam data. Data yang tidak lengkap atau tidak konsisten akan dibersihkan dan diproses lebih lanjut sebelum digunakan dalam model prediksi.

### 2. Preprocessing Data

Sebelum data digunakan untuk pelatihan model, beberapa langkah *preprocessing* dilakukan:

- Pembersihan Data: Nilai yang hilang diisi dengan nol, dan *outlier* diidentifikasi dan ditangani untuk memastikan integritas data.
- Normalisasi Data: Data dinormalisasi ke dalam rentang 0 hingga 1 menggunakan metode *Min-Max Scaling*, yang membantu dalam mempercepat proses pelatihan model dan meningkatkan akurasi prediksi.
- Pembagian Data: Dataset dibagi menjadi dua bagian: 80% untuk pelatihan dan 20% untuk pengujian. Pembagian ini dilakukan secara acak untuk memastikan bahwa model dapat generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya.

### 3. Pembentukan Model

Model yang digunakan dalam penelitian ini adalah *Long Short-Term Memory* (LSTM), yang merupakan jenis *Recurrent Neural Network* (RNN) yang dirancang untuk menangani data urutan panjang. Proses pembentukan model meliputi langkah-langkah berikut:

- Menentukan *Input Shape*: Menentukan bentuk data yang akan dimasukkan ke dalam model berdasarkan jumlah fitur dan panjang urutan.
- Menambahkan Lapisan LSTM: Beberapa lapisan LSTM ditambahkan dengan jumlah unit tertentu dan fungsi aktivasi yang sesuai.
- Menambahkan Lapisan Output: Lapisan *Dense* ditambahkan untuk menghasilkan prediksi akhir.
- Kompilasi Model: Model dikompilasi menggunakan optimizer Adam dan fungsi kerugian *Mean Squared Error* (MSE).

#### 4. Pelatihan Model

Model dilatih menggunakan data pelatihan selama sejumlah *epoch* tertentu dengan ukuran *batch* yang ditentukan. Selama pelatihan, model dievaluasi menggunakan data validasi untuk memantau kinerja dan mencegah *overfitting*. Teknik *early stopping* diterapkan untuk menghentikan pelatihan jika tidak ada peningkatan dalam metrik evaluasi selama beberapa *epoch* berturut-turut.

#### 5. Evaluasi Kinerja Model

Setelah pelatihan selesai, model dievaluasi menggunakan data pengujian. Metrik yang digunakan untuk mengevaluasi kinerja model meliputi:

- *Mean Absolute Error* (MAE): Mengukur rata-rata kesalahan absolut antara nilai prediksi dan nilai aktual.
- *Root Mean Square Error* (RMSE): Mengukur akar kuadrat dari rata-rata kesalahan kuadrat.
- *Mean Absolute Percentage Error* (MAPE): Mengukur kesalahan dalam persentase, memberikan gambaran tentang akurasi prediksi relatif terhadap nilai aktual.

### HASIL DAN PEMBAHASAN

Dataset penggunaan listrik seperti yang diperlihatkan oleh Tabel 1 adalah data aktual selama kurun waktu 1 Tahun. Prediksi penggunaan daya listrik kedepanya adalah berdasarkan siklus waktu data aktual tersebut yaitu dimulai sejak 01 januari 2020 hingga 2021. Bila terdapat data aktual ditahun 2020 maka dapat dibandingkan data hasil prediksi berdasar data 2019 dengan hasil prediksinya, demikian juga bila diketahui data aktual 2021 maka dapat diperkirakan data prediksi ditahun 2022. Hal yang dapat membangun kepercayaan dari model prediksi ini adalah kinerja hasil prediksi yang diukur secara matematis yaitu melalui pengukuran *Mean Absolute Error* (MAE), *Root Mean square Error*, *Mean Absolute Percentage Error* dan Koefisien determinan. Hasil metrik kinerja prediksi penggunaan daya listrik perlatan lampu AC dan *plug* (11 variabel) diperlihatkan sebagai berikut.

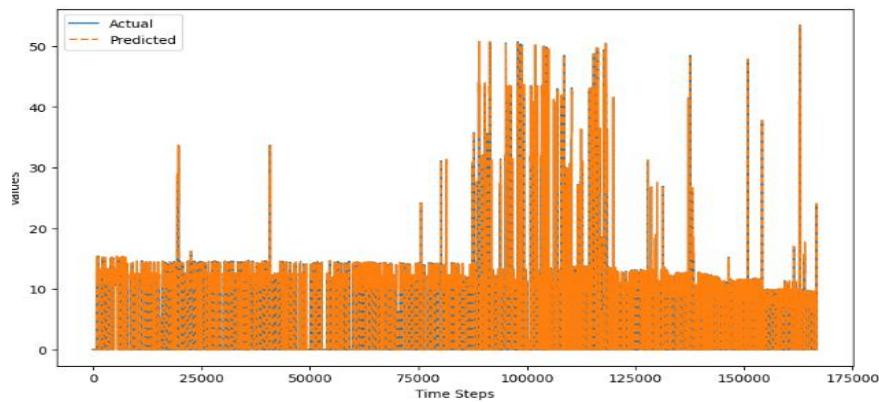
Tabel 2. Metrik kinerja model LSTM penggunaan daya listrik pada lampu

Metrik	Lamp_1	Lamp_2	Lamp_3	Lamp_4
MAE	0.0336	0.08153	0.03481	0.07184
RMSE	0.0548	0.08333	0.05823	0.07478
MAPE	2.148%	1.181%	0.29151%	34.9190%
R <sup>2</sup>	0.999	0.99943	0.9999	0.99998

Tabel 1 menunjukkan kinerja model LSTM dalam memprediksi data penggunaan daya listrik yang masing masing memiliki bobot kinerja berbeda. Model LSTM yang digunakan dalam memprediksi penggunaan daya listrik, terlihat bahwa pada Lamp\_1, Lamp\_2, dan Lamp\_3. Ketiga lampu ini memiliki nilai MAE dan RMSE yang rendah, serta R<sup>2</sup> yang hampir sempurna, menunjukkan bahwa model mampu menangkap pola penggunaan daya listrik dengan baik. Lamp\_3 bahkan menunjukkan akurasi prediksi tertinggi dengan MAPE yang sangat rendah, di bawah 1%. Namun, Lamp\_4 menunjukkan kesulitan dalam prediksi, terlihat dari nilai MAPE yang sangat tinggi (34.9%), yang

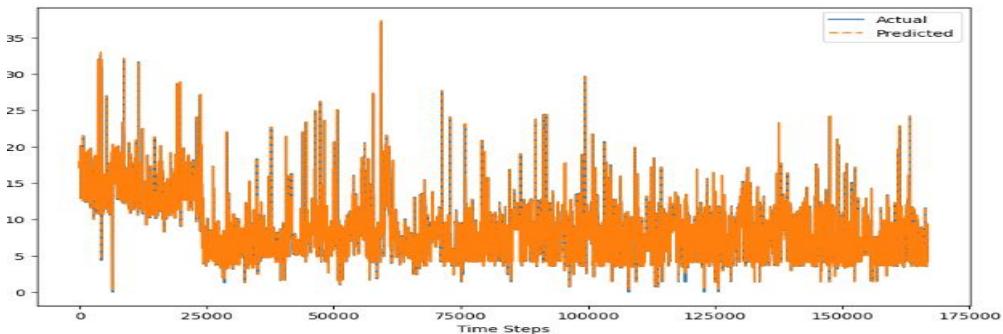
menandakan adanya pola yang kompleks atau variasi data yang sulit ditangkap oleh model LSTM. Secara keseluruhan, LSTM efektif dalam memprediksi data *time series* untuk penggunaan daya listrik, tetapi performa pada Lamp\_4 memerlukan analisis lebih mendalam untuk memahami faktor-faktor yang mempengaruhi akurasi prediksi.

Gambaran bagaimana Kinerja LSTM dalam memprediksi selain ditunjukkan dengan metric kinerja berikut diVisulisasikan bagaimana data aktual dan hasil prediksi disandingkan yang menunjukkan secara keseluruhan pola hasil prediksi mengikuti pola dataset aktual yang terjadi sebelumnya seperti ditunjukkan dengan gambar berikut

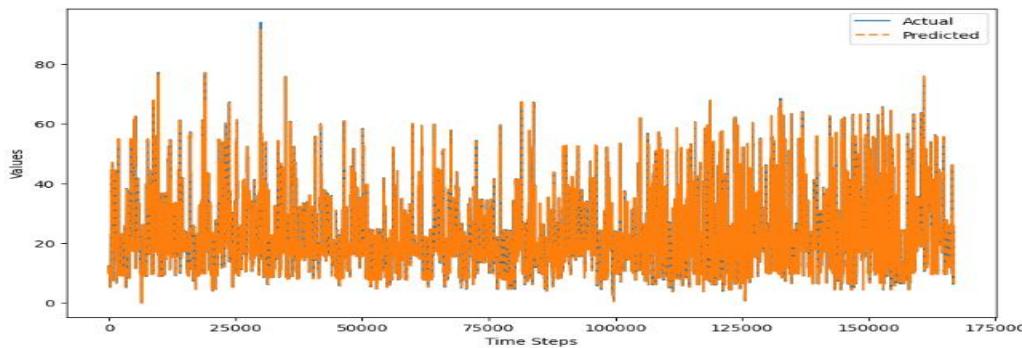


Gambar 2. Hasil Prediksi dan Aktual pada Penggunaan daya Listrik Lamp\_1

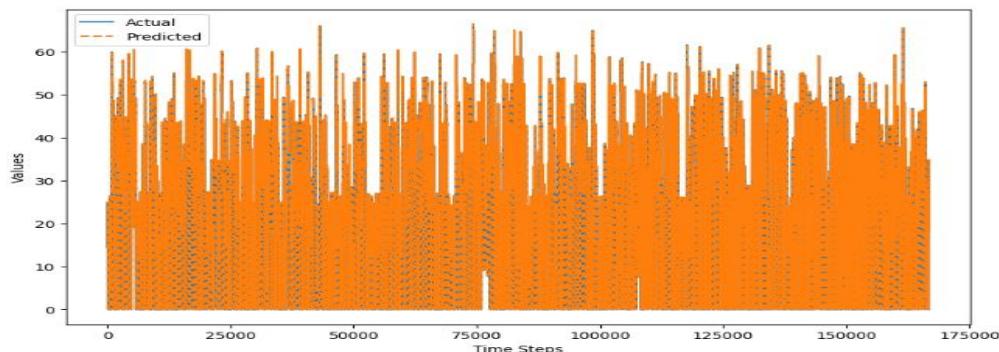
Gambar 1 memperlihatkan bahwa hasil prediksi sangat dekat dengan data aktual. Kondisi ini disebabkan oleh data Lamp\_1 yang lengkap yang sebelumnya bagian data yang dilakukan pembersihan dengan penggantian data NaN dengan nol dan data kosong dengan interpolasi



Gambar 3. Hasil Prediksi dan Aktual pada Penggunaan daya Listrik Lamp\_2



Gambar 4. Hasil Prediksi dan Aktual pada Penggunaan daya Listrik Lamp\_3



Gambar 5. Hasil Prediksi dan Aktual pada Penggunaan daya Listrik Lamp\_4

Gambar 1 hingga gambar 4 menunjukkan Grafik perbandingan penggunaan daya listrik Lamp\_1 menunjukkan bahwa model LSTM berhasil memprediksi dengan baik, terlihat dari pola prediksi yang mengikuti data aktual secara konsisten. Meski ada fluktuasi tinggi dalam data, prediksi tetap mencerminkan tren umum, dengan sebagian besar nilai aktual dan prediksi tampak tumpang tindih. Hal ini mengindikasikan bahwa model LSTM mampu menangani pola kompleks pada penggunaan daya Lamp\_1, meskipun terdapat kurang akurat pada beberapa puncak tertinggi. Secara keseluruhan, model ini memberikan hasil yang memadai dalam memprediksi pola penggunaan daya listrik.

## KESIMPULAN

Penggunaan model *Long Short Term Memory* efektif dalam memprediksi konsumsi daya listrik di bangunan gedung. Dengan memanfaatkan dataset time series yang terdiri dari 525598 baris data dan 11 fitur relevan, penelitian ini berhasil menunjukkan bahwa model LSTM dapat menangkap pola kompleks dalam penggunaan listrik. Metrik kinerja yang digunakan, seperti *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE), menunjukkan bahwa model ini memiliki akurasi yang baik dalam prediksi.

Implikasi dari hasil penelitian ini adalah bahwa model RNN dapat diterapkan untuk manajemen energi yang lebih efisien di bangunan gedung, membantu dalam perencanaan penggunaan listrik di masa depan, serta memberikan wawasan berharga tentang perilaku konsumsi energi. Dengan demikian, penelitian ini berkontribusi pada upaya mitigasi lingkungan terkait dengan pengelolaan energi dan efisiensi penggunaan listrik di sektor bangunan.

**DAFTAR PUSTAKA**

- [1] L. Zhang *et al.*, “A review of machine learning in building load prediction,” *Appl. Energy*, vol. 285, p. 116452, 2021, doi: <https://doi.org/10.1016/j.apenergy.2021.116452>.
- [2] Z. Wang, T. Hong, and M. A. Piette, “Building thermal load prediction through shallow machine learning and deep learning,” *Appl. Energy*, vol. 263, p. 114683, 2020, doi: <https://doi.org/10.1016/j.apenergy.2020.114683>.
- [3] A. Rahman, V. Srikumar, and A. D. Smith, “Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks,” *Appl. Energy*, vol. 212, pp. 372–385, 2018, doi: <https://doi.org/10.1016/j.apenergy.2017.12.051>.
- [4] J. Massana, C. Pous, L. Burgas, J. Melendez, and J. Colomer, “Short-term load forecasting for non-residential buildings contrasting artificial occupancy attributes,” *Energy Build.*, vol. 130, pp. 519–531, 2016, doi: <https://doi.org/10.1016/j.enbuild.2016.08.081>.
- [5] M. A. Mat Daut, M. Y. Hassan, H. Abdullah, H. A. Rahman, M. P. Abdullah, and F. Hussin, “Building electrical energy consumption forecasting analysis using conventional and artificial intelligence methods: A review,” *Renew. Sustain. Energy Rev.*, vol. 70, pp. 1108–1118, 2017, doi: <https://doi.org/10.1016/j.rser.2016.12.015>.
- [6] T. Ahmad and H. Chen, “A review on machine learning forecasting growth trends and their real-time applications in different energy systems,” *Sustain. Cities Soc.*, vol. 54, p. 102010, 2020, doi: <https://doi.org/10.1016/j.scs.2019.102010>.
- [7] C. Fan, F. Xiao, and Y. Zhao, “A short-term building cooling load prediction method using deep learning algorithms,” *Appl. Energy*, vol. 195, pp. 222–233, 2017, doi: <https://doi.org/10.1016/j.apenergy.2017.03.064>.
- [8] T.-Y. Kim and S.-B. Cho, “Predicting residential energy consumption using CNN-LSTM neural networks,” *Energy*, vol. 182, pp. 72–81, 2019, doi: <https://doi.org/10.1016/j.energy.2019.05.230>.
- [9] T. Le, M. T. Vo, T. Kieu, E. Hwang, S. Rho, and S. W. Baik, “Multiple Electric Energy Consumption Forecasting Using a Cluster-Based Strategy for Transfer Learning in Smart Building,” *Sensors*, vol. 20, no. 9. 2020. doi: 10.3390/s20092668.
- [10] H. Zhao and F. Magoulès, “A review on the prediction of building energy consumption,” *Renew. Sustain. Energy Rev.*, vol. 16, no. 6, pp. 3586–3592, 2012, doi: <https://doi.org/10.1016/j.rser.2012.02.049>.
- [11] S. Ahady, N. Dev, and A. Mandal, “Urban Residential Buildings’ Energy Consumption Pattern and Efficiency,” *Iran. J. Sci. Technol. Trans. Civ. Eng.*, vol. 46, no. 5, pp. 3963–3978, 2022, doi: 10.1007/s40996-022-00848-3.
- [12] S. Mischos, E. Dalagdi, and D. Vrakas, “Intelligent energy management systems: a review,” *Artif. Intell. Rev.*, vol. 56, no. 10, pp. 11635–11674, 2023, doi: 10.1007/s10462-023-10441-3.
- [13] J. Hwang, D. Suh, and M.-O. Otto, “Forecasting Electricity Consumption in Commercial

Buildings Using a Machine Learning Approach," *Energies*, vol. 13, no. 22. 2020. doi: 10.3390/en13225885.

- [14] A. Franco, E. Crisostomi, and M. Hammoud, "Advanced Monitoring Techniques for Optimal Control of Building Management Systems for Reducing Energy Use in Public Buildings," *Int. J. Sustain. Dev. Plan.*, vol. 18, no. 7, pp. 2025–2035, 2023, doi: 10.18280/ijsdp.180704.
- [15] S. Lee, J. Kim, and D. Jang, "Analysis of Major Temporary Electrical Equipment Consumption and Usage Patterns in Educational Buildings: Case Study," *Sustainability*, vol. 14, no. 17. 2022. doi: 10.3390/su141710783.